

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

WILLIAM GOUVEA BURATTO

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA SUSTENTABILIDADE
ENERGÉTICA: OTIMIZAÇÃO E PREVISÃO DE DEMANDA NA
DESCARBONIZAÇÃO DE USINAS TERMELÉTRICAS DE BIOMASSA**

JOINVILLE

2026

WILLIAM GOUVEA BURATTO

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA SUSTENTABILIDADE
ENERGÉTICA: OTIMIZAÇÃO E PREVISÃO DE DEMANDA NA
DESCARBONIZAÇÃO DE USINAS TERMELÉTRICAS DE BIOMASSA**

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

Orientador: Ademir Nied

JOINVILLE

2026

Buratto , William Gouvea
Aplicação de Aprendizado de Máquina para
Sustentabilidade Energética: Otimização e Previsão de
Demanda na Descarbonização de Usinas Termelétricas de
Biomassa / William Gouvea Buratto. - Joinville. 2026.
184 p.

Orientador: Ademir Nied

Tese (Doutorado) - Universidade do Estado de Santa
Catarina, Centro de Ciências Tecnológicas, Programa de
Pós-Graduação em Engenharia Elétrica, Joinville, 2026.

1. Aprendizado de máquina. 2. Sustentabilidade
energética. 3. Previsão de despacho. 4. Otimização. 5.
Usinas termelétricas.

WILLIAM GOUVEA BURATTO

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA SUSTENTABILIDADE
ENERGÉTICA: OTIMIZAÇÃO E PREVISÃO DE DEMANDA NA
DESCARBONIZAÇÃO DE USINAS TERMELÉTRICAS DE BIOMASSA**

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

Orientador: Ademir Nied

BANCA EXAMINADORA:

Dr. Ademir Nied
UDESC

Membros:

Dr. Carlos Frederico de Oliveira Barro
UFF

Dr. Douglas Wildgrube Bertol
UDESC

Dr. Fernando Buzzulini Prioste
UDESC

Dr. Rafael Ninno Muniz
UFF

Joinville, 06 de Fevereiro de 2026

Este trabalho é dedicado ao meu Pai, Luiz Alfonso Buratto (in memoriam), seu apoio incondicional guiou meus passos. Esta vitória também é dele. Seus exemplos continuarão a guiar minha jornada.

Esta dedicatória ao meu Pai que tive o privilégio de ter sua presença na defesa de Doutorado e que sempre me incentivou a estudar, sendo que quando tive dificuldades de aprendizado e aprovação durante 1 graduação que era Engenharia Ambiental no Paraná. Foi o meu Pai que me possibilitou, me incentivou e foi essencial para eu transferir meu estudo acadêmico para Santa Catarina e finalizar as 2 graduações que foram Engenharia Ambiental na UDESC e Engenharia Elétrica na Universidade do Planalto Catarinense (UNIPLAC), na qual uma delas em Engenharia Elétrica obtive o grau de Doutor em Sistemas Eletroeletrônicos no Programa de Pós Graduação em Engenharia Elétrica (PPGEEL) da Universidade do Estado de Santa Catarina (UDESC).



Figura 1 – Defesa de Doutorado com a presença ilustre de meu Pai.

AGRADECIMENTOS

Agradeço a Deus primeiramente, que está junto com meu Pai no céu, por ter permitido eu alcançar o objetivo de defender um projeto que venho executando com a colaboração de todos, que citarei durante os agradecimentos. Agradeço ao meu Pai, que sempre esteve comigo em momentos importantes. E foi um privilégio ter tido sua presença como um dos mais ilustres participantes junto com minha Mãe. Pude almoçar, junto com o meu Pai, Mãe e namorada, antes da defesa. Depois comemoramos a aprovação da defesa no Garten shopping. E posteriormente conhecemos juntos, a porta do mar do Espinheiros em Joinville, antes deles voltarem para o Paraná. Este dia ficará na minha memória em toda minha vida. Agradeço a Deus, por permitir compartilhar este momento tão importante da minha carreira acadêmica com meu Pai.

Agradeço a minha Mãe, que foi minha maior inspiração para iniciar o Doutorado. Que me ajudou em todos os momentos da minha vida, sempre me incentivando a estudar e com diversos livros, que me indicou no decorrer de toda minha vida.

Agradeço ao meu irmão Luan, que sempre me incentivou a publicar, e melhorar cada vez mais meu currículo, mostrando que estava evoluindo dia a dia.

Agradeço ao Professor Ademir, que sempre contribuiu com correções de todos os textos e artigos que desenvolvemos durante a Tese e reduziu as minhas dificuldades durante a pesquisa, me apoiando com todos os temas que quis trabalhar durante o Doutorado.

Agradeço a banca interna e externa, composta dos Professores: Douglas Bertol, Fernando Prioste, Rafael Muniz e Carlos Frederico. Que indicaram excelentes sugestões para correções, e que planejo trabalhar em artigos com todos, pois, são exemplos que eu planejo seguir nos meus próximos passos na Universidade, junto com o Professor Ademir e Professor Gabriel.

Agradeço a minha namorada, Julliany Silveira Will Kotona, que me apoiou em todas as etapas do Doutorado, sempre me incentivando a escrever artigos e em trabalhar como Professor de Universidade e em diversas pesquisas que tenho interesse para desenvolver projetos inovadores.

Agradeço aos Doutores: Stefano Stefenon e Rafael Muniz, que foram essenciais na colaboração da escrita, hibridização de algoritmos de IA no Google Colab e MATLAB, gráficos e figuras para publicação de todos os artigos do apêndice, e também os artigos que estamos submetendo conjuntamente após a defesa. Com o apoio de ambos e dos Professores Ademir e Gabriel houve a publicação de 8 artigos científicos durante a minha titulação no Doutorado.

Agradeço ao Doutor: John Jefferson Saldanha, que contribuiu para me ajudar a trabalhar com a plataformas Overleaf e CAPES SCBA e em todos os momentos que precisei durante o Doutorado como o recebimento da primeira bolsa e também com dicas para o Doutorado Sanduíche na Universidade de Salamanca.

Agradeço ao Professor André e a Secretaria Cíntia do Programa de Pós Graduação em Engenharia Elétrica, por me ajudarem durante todo o Doutorado e por serem essenciais em viagens que precisei fazer no Rio de Janeiro para a pesquisa da Tese e no Doutorado Sanduíche para Salamanca.

Agradeço ao Professor Gabriel, com o tratamento que foi me dado na Espanha com excelentes momentos e por ter apoiado em todos os artigos científicos desenvolvidos.

Agradeço a todos do Grupo de Controle de Sistemas (GCS) da UDESC que contribuíram durante os anos em que estive fazendo Doutorado principalmente o Felipe, Fernando Soubhia, Gustavo Bauer, Jessimon Ferreira, João, Lucas, Madson e Vinicius Cidral.

Agradeço ao Salezio Momm e ao Léo Schirmer que estou escrevendo artigos e que me ajudaram no meu desenvolvimento da escrita científica durante o Doutorado.

Agradeço a UDESC por ter me apoiado no Doutorado Sanduíche e por ser uma Universidade que possibilita milhares de pesquisadores e estudantes universitários em alcançarem seus objetivos acadêmicos com incentivos de material, equipamentos e financeiramente. Também agradeço a CAPES por todo o apoio financeiro que contribuiu para que eu pudesse ter tempo para me dedicar na minha pesquisa e por apoiar milhares de outros pesquisadores, colaborando no avanço da pós-graduação ainda recente no Brasil e que tende a melhorar cada vez mais ano após ano.

Agradeço a todos que participaram na defesa de Doutorado, toda minha família e amigos que fizeram e fazem parte da minha vida e contribuíram desde os primeiros anos iniciais da escola até conseguir a aprovação na banca de Doutorado.

“Cada momento histórico corresponde a um conjunto de tendências que estão inter-relacionadas com os modos de produção e organização da sociedade ” (Lucia Gouvea Buratto, [2010])

RESUMO

As usinas termelétricas são sistemas complexos que envolvem múltiplos parâmetros, como pressão, temperatura e vazão de alimentação. O uso de algoritmos de aprendizado de máquina pode otimizar o controle desses parâmetros, aumentando a eficiência operacional e os ganhos ambientais. Prever a demanda de potência dessas usinas por meio de séries temporais é crucial para o planejamento da geração de energia, especialmente porque essas usinas complementam as fontes de geração hidrelétricas no sistema elétrico brasileiro. Além disso, é vital que a gestão energética dessas usinas esteja alinhada com a neutralização de carbono, em conformidade com os protocolos internacionais. Nesta tese foram aplicados diferentes modelos de algoritmos para prever o despacho de energia elétrica, reduzindo custos operacionais, melhorando a estabilidade da rede e potencializando a descarbonização, sendo realizadas comparações de avaliação entre diferentes algoritmos, de modo a alcançar os melhores desempenhos com fusão de diferentes algoritmos de previsão temporal com fluxos de dados complexos. Estes foram aplicados em usinas que utilizam biomassa e também de combustíveis fósseis como carvão, presente principalmente na região sul no Brasil e que precisam adotar medidas de neutralização de carbono. Houve o desenvolvimento na tese de um mecanismo de resiliência contra ataques cibernéticos com diferentes algoritmos de aprendizado de máquina para otimização da descarbonização com o uso de biocarvão derivado de biomassa gerado por usinas de pirólise que consiste em uma solução adaptável e sustentável para diferentes portes de geração. Os resultados desta tese, incluem também uma revisão sistemática de sensores e automação em processos térmicos como incineração, pirólise e gaseificação, além do desenvolvimento de uma metodologia inovadora para alocar diferentes ferramentas tecnológicas visando elevar a geração dos créditos de carbono em diferentes contextos regulatórios.

Palavras-chave: Aprendizado de máquina; Sustentabilidade energética; Previsão de despacho; Otimização; Usinas termelétricas.

ABSTRACT

Thermal power plants are complex systems involving multiple parameters, such as pressure, temperature, and feed flow. The use of machine learning algorithms can optimize the control of these parameters, increasing operational efficiency and environmental gains. Predicting the power demand of these plants using time series is crucial for energy generation planning, especially since these plants complement hydroelectric generation sources in the Brazilian electrical system. In addition, it is vital that the energy management of these plants be aligned with carbon neutrality, in accordance with international protocols. In this thesis, different algorithm models were applied to predict electricity dispatch, reducing operating costs, improving grid stability, and enhancing decarbonization. Evaluative comparisons were made between different algorithms in order to achieve the best performance by merging different time series prediction algorithms with complex data flows. These were applied in power plants that use biomass and also fossil fuels such as coal, mainly present in the southern region of Brazil, which need to adopt carbon neutralization measures. The thesis developed a resilience mechanism against cyber attacks using different machine learning algorithms to optimize decarbonization through the use of biomass-derived biochar generated by pyrolysis plants, which consists of an adaptable and sustainable solution for different generation sizes. The results of this thesis also include a systematic review of sensors and automation in thermal processes such as incineration, pyrolysis, and gasification, as well as the development of an innovative methodology for allocating different technological tools to increase the generation of carbon credits in different regulatory contexts.

Keywords: Machine learning; Energy sustainability; Dispatch forecasting; Optimization; Thermoelectric power plants.

LISTA DE ILUSTRAÇÕES

Figura 1 – Defesa de Doutorado com a presença ilustre de meu Pai.	5
Figura 2 – Processo de pirólise.	36
Figura 3 – Processo de conversão de biomassa.	37
Figura 4 – Processo de gaseificação.	38
Figura 5 – Tecnologias para o tratamento térmico de lodo de esgoto e seus benefícios. . .	64
Figura 6 – Sistemas atuais de tratamento de esgoto.	77
Figura 7 – Sistemas de tratamento alternativos.	81
Figura 8 – Geração de energia da biomassa em relação ao tempo.	89
Figura 9 – Perdas durante treinamento.	90
Figura 10 – Resultados comparativos do valores previstos pelo modelo CNN-LSTM e valores observados.	91
Figura 11 – Plotagens em formatos de violinos dos erros avaliados considerando 50 execuções.	94
Figura 12 – Transformada Wavelet x valores observados.	95
Figura 13 – Valores previstos pela Wavelet CNN-LSTM em relação aos valores observados.	96
Figura 14 – Arquitetura do método híbrido de grupo para tratamento de dados.	100
Figura 15 – Resultados do GMDH de sinais previstos versus observados.	106
Figura 16 – Resultados do HGMDH de sinais previstos versus observados.	107
Figura 17 – Tendências do filtro HP em diferentes valores de lambda (Λ).	114
Figura 18 – Dados originais de séries temporais.	118
Figura 19 – Dados originais da série temporal versus sinal previsto.	121
Figura 20 – Resultados dos testes ao longo das iterações.	121
Figura 21 – Gráfico de hiperajuste da taxa de aprendizado versus unidades LSTM. . . .	122
Figura 22 – Gráfico de hiperajuste do tamanho do kernel versus filtros.	122
Figura 23 – Resultados com valores discrepantes considerando 50 execuções.	123
Figura 24 – Remoção de ruído de dados de séries temporais versus sinal previsto. . . .	124
Figura 25 – Fluxograma de possíveis ataques cibernéticos em um sistema de pirólise. . .	129
Figura 26 – Fluxograma das condições de temperatura para otimização da adsorção de biochar na adsorção de carbono.	132
Figura 27 – Fluxograma da avaliação das características do biocarvão para otimização da adsorção de dióxido de carbono e inserção em banco de dados.	133
Figura 28 – Parâmetros do biochar para melhorar a captura de carbono em diferentes padrões de qualidade.	142
Figura 29 – Ferramentas tecnológicas para reduzir os desafios no mercado de biochar e aumentar a rentabilidade da captura de carbono.	143
Figura 30 – Estrutura para aumentar a captura de carbono e a rentabilidade do biochar. .	144

LISTA DE TABELAS

Tabela 1 – Emissões de CO ₂ de diferentes métodos de tratamento térmico de lodo.	65
Tabela 2 – Parâmetros-chave e aplicações de IA/software para técnicas de descarbonização.	70
Tabela 3 – Comparação de tecnologias de tratamento térmico de lodo.	80
Tabela 4 – Avaliação da proporção de divisão de dados para treinar e testar o modelo e o horizonte de previsão.	91
Tabela 5 – Avaliação do número de camadas e unidades escondidas no modelo de arquitetura.	92
Tabela 6 – Avaliação do otimizador e modelo de taxa de aprendizado.	93
Tabela 7 – Avaliação estatística.	94
Tabela 8 – Análise de nível Wavelet.	95
Tabela 9 – Resultados da variação na porcentagem de dados para treinamento e testes.	104
Tabela 10 – Variação nos resultados do número de neurônios.	105
Tabela 11 – Resultados para a variação no número de camadas.	105
Tabela 12 – Resultados do HGMDH considerando diferentes filtros.	106
Tabela 13 – Avaliação estatística do HGMDH proposto.	107
Tabela 14 – Benchmarking com outros métodos.	108
Tabela 15 – Análise da divisão dos dados (treino/teste).	119
Tabela 16 – Análise do NPTS usado para previsão.	119
Tabela 17 – Análise do tamanho do lote.	120
Tabela 18 – Análise do horizonte de previsão.	120
Tabela 19 – Resultados estatísticos da CF-CNN-BiLSTM hiperajustada com atenção em 50 execuções.	123
Tabela 20 – Análise comparativa de modelos para um horizonte temporal de 6 horas.	124
Tabela 21 – Inteligência artificial/Aprendizado de máquina para aumentar a resiliência e descarbonização contra ataques cibernéticos em usinas de energia de pirólise.	135

LISTA DE ABREVIATURAS E SIGLAS

1D	Unidimensional
ADAM	Estimativa de momento adaptativa (<i>Adaptive Moment Estimation</i>)
AESI	Índice de sustentabilidade energética da Amazônia (<i>Amazon Energy Sustainability Index</i>)
ANFIS	Sistema de inferência neurofuzzy adaptativo (<i>Adaptive neuro fuzzy inference system</i>)
ARIMA	Média móvel integrada autoregressiva (<i>Autoregressive integrated moving average</i>)
ARH	Área de reservatório hidroelétrico
CLPs	Controladores lógicos programáveis
CNN	Rede neural convolucional (<i>Convolutional neural networks</i>)
CO2	Dióxido de carbono
DeepNPTS	Previsor profundo de séries temporais não paramétricas (<i>Deep Non-Parametric Time Series</i>)
ECO	Dimensões econômicas
ENV	Dimensões ambientais (<i>Environmental dimension</i>)
GD	Geração distribuída
GDP	Produto interno bruto (<i>Gross domestic product</i>)
GMDH	Metodologia híbrida de tratamento de dados por grupo (<i>Group Method of Data Handling</i>)
GPU	Unidade de processamento gráfico (<i>Graphics processing unit</i>)
GRU	Unidade recorrente fechadas (<i>Gated recurrent unit</i>)
HGMDH	Grupo híbrido proposto de manipulação de dados (<i>Hybrid Group Method of Data Handling</i>)
HU	Unidades ocultas (<i>Hidden units</i>)
IA	Inteligência artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
INST	Dimensões institucionais
IQR	Intervalo interquartil (<i>Interquartile range</i>)
ISDA	Algoritmo iterativo de dados únicos (<i>Iterative Single Data Algorithm</i>)
KKT	Condições de Karush-Kuhn-Tucke

KOH	Hidróxido de potássio
L1QP	Solucionador de minimização de margem suave L1 por programação quadrática
LIN	Função de Kernel linear
LOESS	Suavização de gráfico de dispersão estimada localmente
LR	Taxa de aprendizagem (<i>Learning rate</i>)
LSE	Erros de mínimos quadrados (<i>Least Squares Error</i>)
LSTM	Memória de longo e curto prazo (<i>Long short-term memory</i>)
MAE	Erro absoluto médio (<i>Mean Absolute Error</i>)
MAPE	Erro percentual absoluto médio (<i>Mean Absolute Percentage Error</i>)
Máx.	Máximo
MFs	Funções de associação (<i>Membership functions</i>)
Mín.	Mínimo
ML	Aprendizado de máquina (<i>Machine learning</i>)
MSE	Erro quadrático médio (<i>Mean squared error</i>)
N	Norte
NaOH	Hidróxido de sódio
NBEATS	Análise de expansão de base neural (<i>Neural Basis Expansion Analysis for Time Series Forecasting</i>)
NHITS	Interpolação hierárquica neural para séries temporais (<i>Neural Hierarchical Interpolation for Time Series Forecasting</i>)
NE	Nordeste
ONS	Operador nacional do setor elétrico
POLY	Função de base polinomial
Pop	População
RAM	Memória de acesso aleatório (<i>Random-access memory</i>)
RBF	Função de base radial (<i>Radial basis function</i>)
REC	Consumo de energia residencial (<i>Residential energy consumption</i>)
RMSProp	Propagação de raiz quadrada média (<i>Root Mean Square Propagation</i>)
RNA	Rede neural artificial
RNAs	Redes neurais artificiais
RNN	Rede neural recorrente (<i>Recurrent neural network</i>)

SMO	Otimização mínima sequencial (<i>Sequential minimal optimization</i>)
SCADA	Sistema de controle e aquisição de dados
Seq2Seq	Sequência por sequência
SGD	Método do gradiente estocástico (<i>Stochastic gradient descent</i>)
SGDM	Descida de gradiente estocástica com momentum (<i>Stochastic gradient descent with momentum</i>)
SIN	Sistema interconectado Nacional
SOC	Dimensões sociais
SSA	Análise espectral singular (<i>Singular spectrum analysis</i>)
TCN	Redes convolucionais temporais (<i>Temporal Convolutional Networks</i>)
TCO2	Emissões de dióxido de carbono equivalente
TEC	Dimensões técnicas
Temp.	Temperatura
TFC	Consumo final total (<i>Total final consumption</i>)
TNR	Geração não renovável total (<i>Total non-renewable</i>)
TPES	Total de Fontes de Energia primária (<i>Total primary energy sources</i>)
TRE	Energia renovável total (<i>Total Renewable energy</i>)
UDESC	Universidade do Estado de Santa Catarina
VMD	Decomposição do modo variacional (<i>Variational Mode Decomposition</i>)

LISTA DE SÍMBOLOS

\tilde{c}_t	Estado da célula candidata
c_t	Estado da célula
Θ	Vetor de contexto
f_t	Esquecer porta
h_t	Estado oculto
i_t	Porta de entrada
o_t	Porta de saída
\hat{y}_t	Saída prevista
y_t	Sequência de saída desejada
t	Passo de tempo
\hat{y}_{new}	Previsão final
x_{new}	Nova entrada
Z_t	Fator de normalização para garantir que os pesos somem 1
Y_i	Previsões feitas pelo i -ésimo modelo de base em sua respectiva amostra bootstrap X_i
\hat{y}	Valor previsto do valor observado
w	Critérios de regularidade
P	Número de conjuntos de teste
Y_t	Passeio aleatório
ε_t	Um termo de erro estocástico
(\hat{Y}_t)	Tendência
d	Largura de banda
S_t	Componentes sazonais de tendência
R_t	Componentes sazonais residuais
x_2	Cenário com mais solicitações de geração
x_1	Cenário com menos demanda

SUMÁRIO

1	INTRODUÇÃO	29
1.1	CONSIDERAÇÕES GERAIS	29
1.2	MOTIVAÇÃO	30
1.3	OBJETIVOS GERAL E ESPECÍFICOS	30
1.4	QUESTÃO DA PESQUISA	31
1.5	CONTRIBUIÇÕES DA TESE	31
1.6	PUBLICAÇÕES RELACIONADAS À PROPOSTA	32
1.7	ORGANIZAÇÃO DO DOCUMENTO	33
2	REVISÃO BIBLIOGRÁFICA	35
2.1	RECUPERAÇÃO ENERGÉTICA DE RESÍDUOS	35
2.2	ESTRATÉGIAS DE OPERAÇÃO ÓTIMA E GERENCIAMENTO TÁTICO	38
2.2.1	Despacho Econômico em Sistemas Térmicos	40
2.3	PROCESSOS DE INCINERAÇÃO, GASEIFICAÇÃO E PIRÓLISE	42
2.4	FATORES IMPORTANTES NA GERAÇÃO TÉRMICA	45
2.4.1	Influência da Temperatura	45
2.4.2	Importância da Pressão Constante	46
2.4.3	Taxa de Aquecimento	46
2.4.4	Importância do Tempo	46
2.5	AUTOMAÇÃO E IA NOS PROCESSOS TÉRMICOS	47
2.5.1	Monitoramento no Tratamento Térmico de Resíduos	47
2.5.2	Sensores em Termoelétricas	48
2.5.3	Previsão de Séries Temporais Usando IA	48
2.6	COMBUSTÍVEIS E PRODUTOS DERIVADOS PARA ÁREA ELÉTRICA	53
2.6.1	Gás de síntese na geração de eletricidade	53
2.6.2	Biocarvão na produção de super capacitores	54
2.6.3	Amônia Verde na Geração de Energia Elétrica	56
2.7	DESCARBONIZAÇÃO NA GERAÇÃO TERMOELÉTRICA COM LODO	57
2.7.1	Técnicas de Descarbonização	59
2.7.2	Estado da arte da descarbonização em tratamentos térmicos de lodo para geração de energia elétrica considerando sensores e a aplicação de inteligência artificial	63
2.7.3	Tratamento térmico de lodo	69
2.7.4	Aplicações de IA no tratamento de lodo	75
2.8	FATORES IMPORTANTES PARA A IMPLEMENTAÇÃO DA CAPTURA DE CARBONO NO TRATAMENTO DE LODO	76

2.9	ALTERAÇÕES NECESSÁRIAS NA ESTAÇÃO DE TRATAMENTO DE ÁGUAS RESIDUAIS PARA REDUZIR O CO ₂	79
2.10	CONSIDERAÇÕES FINAIS DO CAPÍTULO	81
3	ALGORITMOS BASEADOS EM INTELIGÊNCIA ARTIFICIAL	85
3.1	CNN-LSTM PARA PREVISÃO	85
3.1.1	Arquitetura do CNN-LSTM	86
3.1.2	Remoção de Ruído Através da Transformada Wavelet	88
3.1.3	Base de Dados para o Experimento	88
3.1.4	Resultados e Discussões	90
3.1.5	Avaliação do Modelo CNN-LSTM	90
3.1.6	Avaliação Estatística	93
3.1.7	Avaliação de Filtragem	94
3.1.8	Considerações Finais sobre o modelo CNN-LSTM	95
3.2	MÉTODO HÍBRIDO DE PROCESSAMENTO DE DADOS EM GRUPO PARA PREVISÃO DE SÉRIES TEMPORAIS DO DESPACHO DE GERAÇÃO TÉRMICA EM SISTEMAS DE ENERGIA ELÉTRICA	96
3.2.1	Introdução	96
3.2.2	Metodologia	98
3.2.3	Estágio de redução de ruído de entrada	98
3.2.3.1	<i>Filtro Christiano-Fitzgerald</i>	98
3.2.3.2	<i>Filtro Hodrick-Prescott</i>	99
3.2.4	Decomposição da tendência sazonal usando LOESS	99
3.2.5	Método de agrupamento de dados	100
3.2.6	Comparação de modelos	101
3.2.6.1	<i>TFT</i>	101
3.2.6.2	<i>TCN</i>	102
3.2.6.3	<i>LSTM</i>	102
3.2.6.4	<i>ANFIS</i>	103
3.2.7	Conjunto de dados e configuração experimental	103
3.2.8	Índices de avaliação	104
3.2.9	Resultados	104
3.2.10	Método híbrido	106
3.2.11	Benchmarking	107
3.3	CF-CNN-BILSTM HÍBRIDO HIPERAJUSTADO POR OTIMIZAÇÃO BAYESIANA PARA PREVISÃO DE GERAÇÃO DE ENERGIA TÉRMICA E DESCARBONIZAÇÃO	108
3.3.1	Introdução	108

3.3.2	Aplicação do CNN e BiLSTMs	111
3.3.3	Metodologia	112
3.3.4	Filtro Christiano-Fitzgerald (CF)	113
3.3.5	CNN-BiLSTM	114
3.3.6	Otimização Bayesiana	115
3.3.7	Base de dados	117
3.3.8	Configuração do experimento	118
3.3.9	Análise comparativa	118
3.3.10	Resultados	119
3.3.11	Análise de Hiperajuste	121
3.3.12	Análise Estatística	122
3.3.13	Benchmarking	123
3.3.14	Limitações	125
3.4	DESCARBONIZAÇÃO EM USINAS TERMOELÉTRICAS POR ALGORITMOS PARA PREVISÃO DE CARGA	125
3.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	126
4	OTIMIZAÇÃO PARA DESCARBONIZAÇÃO EM USINAS TERMOELÉTRICAS DE BIOMASSA CONTRA ATAQUES CIBERNÉTICOS E DESENVOLVIMENTO DE ESTRUTURA METODOLÓGICA PARA ELEVAR O ALCANCE DOS CRÉDITOS DE CARBONO A PARTIR DE BIOCARVÃO	127
4.0.1	Introdução sobre otimização para descarbonização	127
4.0.2	Metodologia do sistema de otimização	129
4.0.3	Resultados avaliados em Usina de Pirólise de lodo	131
4.1	ESTRUTURA TECNOLÓGICA PARA ELEVAR CRÉDITO DE CARBONO ATRAVÉS DE BIOCARVÃO COM DIFERENTES NORMAS REGULAMENTADORAS	136
4.1.1	Introdução sobre a estrutura tecnológica	136
4.1.2	Metodologia da estrutura de certificação de baixo carbono	139
4.1.3	Resultados e discussão sobre o desenvolvimento de ferramentas tecnológicas para elevar o alcance de créditos de carbono	142
4.2	CONSIDERAÇÕES FINAIS DO CAPÍTULO	144
5	CONSIDERAÇÕES FINAIS	145
5.0.1	Recomendações para trabalhos futuros	147
	REFERÊNCIAS	149

APÊNDICES - ARTIGOS PUBLICADOS	185
APÊNDICE A – A REVIEW OF AUTOMATION AND SENSORS: PARAMETER CONTROL OF THERMAL TREAT- MENTS FOR ELECTRICAL POWER GENERATION	187
APÊNDICE B – SEQ2SEQ-LSTM WITH ATTENTION FOR ELEC- TRICITY LOAD FORECASTING IN BRAZIL . . .	211
APÊNDICE C – WAVELET CNN-LSTM TIME SERIES FORECAS- TING OF ELECTRICITY POWER GENERATION CONSIDERING BIOMASS THERMAL SYSTEMS .	221
APÊNDICE D – TIME SERIES FORECASTING OF THERMAL SYS- TEMS DISPATCH IN LEGAL AMAZON USING MACHINE LEARNING	237
APÊNDICE E – HYBRID GROUP METHOD OF DATA HANDLING FOR TIME-SERIES FORECASTING OF THERMAL GENERATION DISPATCH IN ELECTRICAL POWER SYSTEMS	257
APÊNDICE F – HYBRID CF-CNN-BILSTM HYPERTUNED BY BAYE- SIAN OPTIMIZATION FOR THERMAL POWER GENERATION AND DECARBONIZATION FORE- CASTING	275
APÊNDICE G – STATE-OF-THE-ART DECARBONIZATION IN SLUDGE THERMAL TREATMENTS FOR ELECTRICAL POWER GENERATION CONSIDERING SENSORS AND THE APPLICATION OF ARTIFICIAL INTELLIGENCE	289
APÊNDICE H – TIME SERIES FORECASTING BASED ON MULTI- CRITERIA OPTIMIZATION FOR MODEL AND FILTER SELECTION APPLIED TO HYDROELEC- TRIC POWER PLANTS	325

1 INTRODUÇÃO

Os desafios da integração de sustentabilidade e maximização na conversão de bioenergia podem ser solucionados a partir da combinação de algoritmos de inteligência artificial como redes neurais artificiais, modelagem por lógica Fuzzy, com programação linear (BATISTA *et al.*, 2023), de modo a minimizar os custos e as emissões desse processo. A performance preditiva consta também como outra premissa de alta relevância em usinas termoelétricas, pois tem a capacidade de aumentar a rentabilidade do processo e aprimorar a qualidade do controle por meio da verificação de rendimento antecipada, sendo que a técnica de redes neurais artificiais é altamente empregada devido ao aprendizado extremo, mesmo quando se tem correlações de entrada e saída não lineares, como o que ocorre em processos termoquímicos (NAQVI *et al.*, 2023).

1.1 CONSIDERAÇÕES GERAIS

Modelos de aprendizagem de máquina podem ajudar a reduzir incertezas nos aspectos econômicos e ambientais em usinas de pirólise (AKINPELU *et al.*, 2023). A partir de uma revisão de literatura os autores verificaram a possibilidade de aplicar modelos de regressão com baixa demanda computacional e acurácia, incorporando dentro destas modelagens, as análises de estudos de viabilidade técnico-econômica e de ciclo de vida, as quais poderiam otimizar a geração energética e minimizar as emissões. No entanto, segundo os mesmos pesquisadores, a disponibilidade de dados e essa estruturação do algoritmo constam como os principais desafios dessa implementação.

Estes modelos de predição incorporados na carga e despacho desses modelos de usinas reduzem os custos da geração de potência elétrica e colaboram na ininterrupção de potência para consumidores, sendo que a acurácia de cada técnica pode ser verificada por métodos estatísticos e depende da base de dados e do tempo de duração dessa previsão, que pode ser estabelecida desde minutos até meses (podendo ser de mais de um ano). As de menor escala de tempo podem ser usadas para agendamento de manutenções e as de maior tempo para avaliação do crescimento de geração, além de ter como benefício a minimização de emissões atmosféricas devido a erradicação de geração de potência excedente (AHMAD *et al.*, 2022).

Dentro dos contextos citados, a agregação de múltiplos algoritmos de inteligência artificial integrados em uma mesma estrutura de programa computacional pode compatibilizar o uso de estratégias de operação, manutenção e planejamento dentro de um modelo de instruções que facilite a operação em usinas termoelétricas de biomassa, maximizando o potencial de alocação desses recursos de biomassa renováveis no setor elétrico brasileiro, aumentando receitas decorrentes da validação por créditos de emissões atmosféricas que estão sendo evitadas e capturadas, além de possibilitar a maior efetividade na geração de potência elétrica e de produtos de cunho energético como os biocombustíveis ou de matérias primas como supercapacitor, que podem ser obtidas a partir do conceito de biorrefinarias.

1.2 MOTIVAÇÃO

A partir do tópico de contextualização apresentado na seção anterior nota-se a importância na verificação de performance dentro das usinas de biomassa. Estas usinas representam uma grande parcela da geração de potência dentro do setor elétrico Brasileiro (MAGNE; KHATTIWADA; CARDOZO, 2024). Valorização por otimização de processos permite o aumento de performance na geração térmica em usinas termoeletrica e alcance de melhores padrões em diversos indicadores de sustentabilidade.(AYUB *et al.*, 2023).

Determinar indicadores que permitam associar os modelos que maximizam ganhos energéticos e ambientais facilita a verificação de inserção por biomassa que possui maior aptidão no processo em usina de pirólise, facilitando na decisão de investimentos e que pode colaborar no coprocessamento térmico de diferentes biomassas (HOWARI *et al.*, 2023).

Esforços na implementação da transição energética devem ser efetivados para o alcance dos objetivos de desenvolvimento sustentável. Ações contra a mudança global do clima podem ter maior escalabilidade com a estruturação das análises de padrões de importância por meio de indicadores e a conjunção de técnicas de inteligência artificial que podem beneficiar a prospecção de estratégias, além de elevar e ranquear o impacto de processos minimizando as dificuldades dessa mudança de fontes energéticas em contextos regionais e nacionais (MOSSO *et al.*, 2024).

Possibilitar a geração de produtos de maior valor agregado e alta qualidade, maximizando o uso eficiente dos recursos naturais e obtendo maior lucro operacional contribui com os aspectos ambientais e econômicos, podendo ser realizada por modelos preditivos e prescritivos, prover análises das raízes de causas de ineficiência e detectar anomalias no processo a partir dos algoritmos de inteligência artificial (ARIAS; FEIJOO; MOREIRA, 2023).

A partir da redução das perdas de energia e suavização da curva de carga, melhorias significativas na qualidade e na eficiência no sistema de potência são alcançadas. Levando isso em consideração, os aspectos destacados acima serviram de motivação para esta tese, na qual se propõe uma estratégia para a alocação otimizada de recursos no sistema elétrico de distribuição, levando em consideração a operação otimizada de um sistema de armazenamento de energia.

1.3 OBJETIVOS GERAL E ESPECÍFICOS

O objetivo geral da tese é aplicar um modelo computacional por meio de algoritmos de aprendizado de máquina para otimizar a eficiência em usinas termoeletricas a biomassa, prevendo sua demanda integrada de geração.

Os objetivos específicos desta tese são:

- Avaliar a importância da variação de parâmetros de controle de sistemas térmicos de tratamento de biomassa para geração de eletricidade buscando minimizar as perdas de energia ativa.

- Aplicar algoritmos de previsão de geração de energia elétrica considerando conjuntos de sistemas térmicos por biomassa para o melhor entendimento das necessidades dos sistemas, auxiliando na tomada de decisão sobre a gestão dos recursos para geração de energia no setor elétrico.
- Analisar as principais técnicas de captura de carbono utilizadas atualmente e determinar quais coeficientes precisam ser adaptados, de modo que concilie a produtividade elétrica com a redução de emissões de gases em usina termelétricas.

1.4 QUESTÃO DA PESQUISA

Esta pesquisa investiga o conceito de previsão de carga e despacho com potencial de descarbonização por meio de algoritmos de inteligência artificial, realizando em conjunto a fundamentação de diferentes ferramentas tecnológicas para otimizar a descarbonização em usinas termoeletricas com a seguinte pergunta orientadora:

Podem ser alcançados erros baixos na previsão de carga e despacho de energia elétrica reduzindo desperdícios de combustível fóssil e biomassa em usinas termoeletricas com a mitigação de emissões e aumentando lucros operacionais?

Uma resposta provável seria o desenvolvimento por hibridização com diferentes algoritmo que permita obter baixos erros de previsão na carga e despacho de eletricidade em usinas termoeletricas associado a aplicação de outras ferramentas tecnológicas desenvolvidas neste século como blockchain, contratos inteligentes e tokenizar estes ativos . O objetivo desta tese é aplicar modelos de IA com dados reais de operações de usinas termoeletricas brasileiras e estruturar sistemas desenvolvidos recentes para que sejam avaliados diferentes integrações fundamentadas nesta pesquisa e desenvolvidos em trabalhos futuros a integração em diferentes usinas termoeletricas brasileiras e em outros países.

1.5 CONTRIBUIÇÕES DA TESE

O desenvolvimento de algoritmos que possibilitem o aprimoramento das ações de mitigação e captura de dióxido de carbono e, conseqüentemente, maior obtenção de créditos derivados da redução das emissões de carbono na área termoeletrica em conjunto com o planejamento de maior efetividade dos recursos energéticos, pode beneficiar o setor elétrico brasileiro, possibilitando aumento de receita aliado a menor impacto ambiental, e permite que os co-produtos sólidos e líquidos (complementares) dessas usinas como o biocarvão e bioóleo, apresentem maior valor agregado no mercado interno e externo.

A significação e parametrização dos indicadores de sustentabilidade energética pode beneficiar a adoção de melhores práticas de mitigação ou redução de impactos ambientais por meio desse ranqueamento em um índice que também permite a verificação dos municípios e estados do Brasil que possuem maior aptidão da inserção de usinas de reaproveitamento de

biomassa residual, avaliando principalmente os indicadores de geração renovável, intensidade energética, intensidade de carbono e produtividade energética.

1.6 PUBLICAÇÕES RELACIONADAS À PROPOSTA

Houve a publicação de sete artigos científicos, que foram diretamente derivados deste trabalho de tese. O primeiro artigo publicado é uma revisão de literatura avaliando os parâmetros de controle nos sensores em tratamentos térmicos de biomassa. O segundo artigo publicado está relacionados a área de previsão de carga e despacho focando no cenário Brasileiro e o quarto artigo na mesma linha focado na região da Amazônia Legal. O terceiro artigo publicado avalia a previsão da geração de eletricidade considerando sistemas térmicos de biomassa no Brasil, nas maiores usinas do Sistema Interconectado Nacional (SIN), avaliando a previsão de séries temporais da disponibilidade de biomassa e geração de energia elétrica, verificando a performance nas aplicações em escala real. No quinto artigo publicado foi proposto um método híbrido de processamento de dados em grupo para previsão de series temporais no despacho de geração térmica. O sexto artigo publicado focou na previsão de geração de energia térmica e descarbonização em usina de carvão. No sétimo artigo publicado foi realizada uma revisão do estado da arte da descarbonização em tratamentos térmicos de lodo para geração de energia aplicando em conjunto sensores com modelos de IA. O oitavo artigo publicado se trata de uma otimização multi critério e seleção de filtros aplicado em usina hidroelétrica. Este oitavo artigo publicado não foi derivado da tese mas tem relação com a temática desenvolvida na tese, embora tenha sido aplicado em Usinas Hidroelétricas.

A relação dos artigos citados está descrita a seguir:

- Artigo em periódico (publicado) – disponível no APÊNDICE A:

Buratto, W. G., Muniz, R. N., Nied, A., Barros, C. F. D. O., Cardoso, R., Gonzalez, G. V. A Review of automation and sensors: Parameter control of thermal treatments for electrical power generation. **Sensors**, volume 24, número 3, páginas 967, 2024.

- Artigo em periódico (publicado) – disponível no APÊNDICE B:

Buratto, W. G., Muniz, R. N., Nied, A., Gonzalez, G. V. Seq2Seq-LSTM with attention for electricity load forecasting in Brazil. **IEEE Access**, volume 12, páginas 30020-30029, 2024.

- Artigo em periódico (publicado) – disponível no APÊNDICE C:

Buratto, W. G., Muniz, R. N., Nied, A., Barros, C. F. D. O., Cardoso, R., Gonzalez, G. V. Wavelet CNN-LSTM time series forecasting of electricity power generation considering biomass thermal systems. **IET Generation, Transmission & Distribution**, volume 18, número 21, páginas 3437-3451, 2024.

- Artigo em periódico (publicado) – disponível no APÊNDICE D:
Buratto, W. G., Muniz, R. N., Cardoso, R., Nied, A., da Costa, C. T., Gonzalez, G. V. Time series forecasting of thermal systems dispatch in legal Amazon using machine learning. **Applied Sciences**, volume 14, número 21, página 9806, 2024.
- Artigo em periódico (publicado) – disponível no APÊNDICE E:
Buratto, W. G., Muniz, R. N., Cardoso, R., Nied, A., da Costa Jr, C. T., Gonzalez, G. V.. Hybrid group method of data handling for time-series forecasting of thermal generation dispatch in electrical power systems. **Electrical Engineering**, volume 107, número 10, páginas 13929-13945, 2025.
- Artigo em periódico (publicado) – disponível no APÊNDICE F:
Buratto, W. G., Muniz, R. N., Nied, A., de Oliveira Barros, C. F., Finardi, E. C., Gonzalez, G. V. Hybrid CF-CNN-BiLSTM hypertuned by Bayesian optimization for thermal power generation and decarbonization forecasting. **International Journal of Electrical Power & Energy Systems**, volume 172, página 111199, 2025.
- Artigo em periódico (publicado) – disponível no APÊNDICE G:
Muniz, R. N., Buratto, W. G., Cardoso, R., Barros, C. F. D. O., Nied, A., & Gonzalez, G. V. State-of-the-Art Decarbonization in Sludge Thermal Treatments for Electrical Power Generation Considering Sensors and the Application of Artificial Intelligence. **Water**, volume 17, número 13, página 1946, 2025.
- Artigo em periódico (publicado) – disponível no APÊNDICE H:
Muniz, R. N., Stefenon, S. F., Buratto, W. G., Nied, A., Cardoso, R., Yamaguchi, C. K., & Yow, K. C. Time series forecasting based on multi-criteria optimization for model and filter selection applied to hydroelectric power plants. **Energy**, página 138688, 2025.

1.7 ORGANIZAÇÃO DO DOCUMENTO

Esta tese está dividida em cinco capítulos. Inicialmente, na introdução são estabelecidos os objetivos da tese, contribuições, publicações e a descrição dos capítulos que compõe o texto da tese.

No Capítulo 2, é descrita uma revisão da literatura científica abrangendo os aspectos da inteligência artificial no cenário nacional e internacional e a regulamentação atual, e apresenta os diversos algoritmos na caracterização de sustentabilidade energética, previsão de despacho e otimização nas fontes de geração de energia elétrica, com metodologias de operação ótima e gerenciamento tático, de modo a minimizar os custos de operação.

Em relação ao Capítulo 3, este se configura como a base de inicialização na aplicação de diferentes algoritmos, o qual apresenta o conteúdo de um artigo científico que já foi publicado

e fundamenta a concepção da futura tese de doutorado, descrevendo a metodologia e resultados obtidos na previsão da geração e despacho no setor termoelétrico, que corresponde a um percentual elevado dentro das usinas complementares do SIN considerando os dados obtidos no sistema do Operador Nacional do Sistema (ONS), em que foram verificadas a produção não linear das maiores usinas termelétricas do Brasil.

Por sua vez, no Capítulo 4, são apresentados o desenvolvimento de mecanismos de resiliência contra ataques cibernéticos com otimização para descarbonização em sistema de pirólise em diferentes contextos regulatórios.

Por fim, no Capítulo 5 são descritas as conclusões obtidas durante a tese, avaliando a capacidade de descarbonização e possível neutralização em usinas fósseis e de biomassa no cenário do SIN.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma revisão da literatura, abordando os principais temas e artigos relacionados à proposta desta tese. O capítulo está dividido em três seções, apresentando ao leitor os avanços que estão sendo alcançados, permitindo uma melhor percepção das estratégias utilizadas para melhoria da sustentabilidade e eficiência energética com foco na aplicação de inteligência artificial (IA). Especificamente, são apresentados os temas de recuperação energética e algoritmos de IA visando maximização de eficiência operacional e ambiental em usinas de recuperação energética por resíduos de biomassa.

2.1 RECUPERAÇÃO ENERGÉTICA DE RESÍDUOS

Os tratamentos termoquímicos são alternativas para resíduos sólidos urbanos ou biomassa, incluindo combustão, pirólise e gaseificação, garantindo a geração de três produtos principais: eletricidade, combustíveis e calor (NANDHINI *et al.*, 2022). Algo que deve ser observado nestas tecnologias é a concentração de entrada de oxigênio que alimenta os reatores, produzindo diferentes rotas térmicas e, conseqüentemente, alterando seus produtos, incluindo combustíveis e emissões de gases perigosos nas usinas de energia (LEDÓN *et al.*, 2016).

As alternativas termoquímicas precisam de diferentes tempos de residência para a estabilidade do processo, e esse período pode determinar os diferentes produtos gerados (KAN; STREZOV; EVANS, 2016). No tratamento de pirólise, o reator depende principalmente dessa variável e, portanto, tem uma influência sobre os produtos gerados por meio das taxas de reação, podendo produzir gás de síntese, bio-óleo e biocarvão com diferentes concentrações em reatores de pirólise lenta, pirólise rápida e pirólise flash (SHARMA; PAREEK; ZHANG, 2015). Um exemplo de processo de pirólise pode ser visualizado na Figura 2.

A co-pirólise de serragem de madeira e lodo de esgoto é uma etapa importante para a recuperação de energia. Estudos provam que é possível melhorar a geração de energia de 141% para 191%, reduzindo a ecotoxicidade, com uma recuperação líquida que chega a 17.097 kWh/tonelada de matéria seca (HUANG; MOHAMED; LI, 2023). Conforme Yang *et al.* (YANG *et al.*, 2023a), a otimização operacional e a recuperação de energia térmica possibilita reduzir as emissões de gases de efeito estufa nas estações de tratamento de águas residuais.

Beik *et al.* (2023) discutiram a viabilidade econômica e a escalabilidade do sistema de pirólise em pequena escala, enfatizando seu potencial para soluções descentralizadas de tratamento de resíduos. Os resultados contribuem para o gerenciamento de lodo, oferecendo uma alternativa para o tratamento sustentável de lodo sanitário em escalas menores. Essa pesquisa marca um passo significativo em direção ao avanço das tecnologias para o descarte responsável de resíduos e a recuperação de recursos no contexto do tratamento de águas residuais.

A conversão de calor e energia combinados a partir de lodo de esgoto pode ser otimizada (FRAIA *et al.*, 2022). A correlação entre a energia interna consumida na estação de tratamento de esgoto e o potencial de recuperação de energia pode ser analisada por meio de modelagem




Figura 2 – Processo de pirólise.
 Fonte: Adaptado de (BURATTO *et al.*, 2024a)

computacional, avaliando a remoção de poluentes (YANG *et al.*, 2023b). Li *et al.* (2023) analisou as pegadas de carbono de três tecnologias térmicas que são a liquefação hidrotérmica (HTL), a pirólise e a incineração com o software OpenLCA, considerando o banco de dados Ecoinvent. O HTL tem a menor emissão de gases de efeito estufa, 172,50 kg CO₂eq/tonelada de lodo de esgoto, enquanto os processos de pirólise e incineração apresentaram 242,02 e 322,23, respectivamente. Estes resultados indicam que o HTL é mais interessante por sua taxa de consumo de energia em relação à energia de entrada e recuperada. Os principais processos de conversão de biomassa estão ilustrados na Figura 3.

A recuperação do catalisador no tratamento térmico, como gaseificação e pirólise, é uma etapa importante para a descarbonização e a economia circular; no entanto, os processos ainda são caros, complexos e podem ser não confiáveis (SUDALAIMUTHU; SATHYAMURTHY, 2024). A pesquisa de tecnologia de secagem de lodo é vital para a descarbonização, uma vez que reduz o consumo de energia e as emissões de carbono. De acordo com Chu *et al.*, esta abordagem é uma das responsáveis pela redução de carbono na China (CHU *et al.*, 2023).

Shi *et al.* (2023b) avaliaram duas tecnologias de tratamento térmico diferentes para o lodo, que foram a incineração e a gaseificação a vapor com captura de carbono por absorção química e looping químico. Os autores relataram custos mais baixos para a gaseificação em relação à incineração, comparativamente, o custo médio da gaseificação é de 47,31\$/tonelada, enquanto a incineração é de 91,76\$/tonelada.

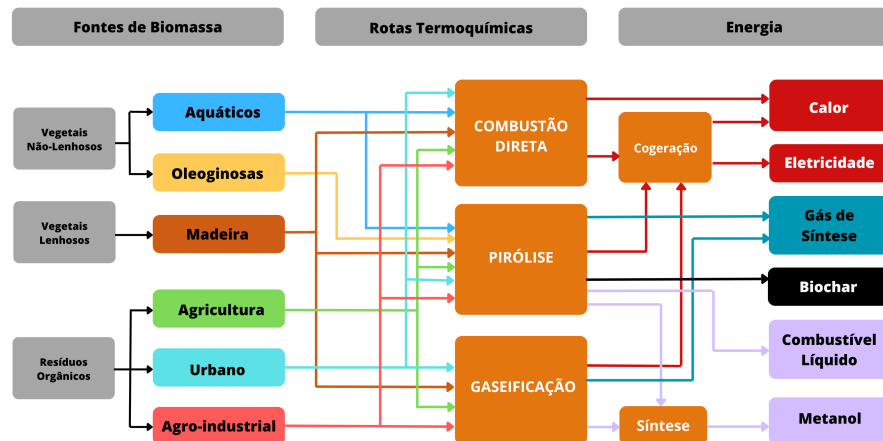


Figura 3 – Processo de conversão de biomassa.
Fonte: Adaptado de (BURATTO *et al.*, 2024a)

O lodo de esgoto municipal, por ser um material com alto teor de umidade, torna-se caro para ser utilizado para geração de energia. Uma análise de pré-tratamento é geralmente feita para otimizar seu potencial de combustível de acordo com os custos associados e possíveis ganhos de energia em uma rota térmica (ADIBIMANESH *et al.*, 2023). Kostowski *et al.* (2024) avaliou a carbonização hidrotérmica de lodo de esgoto desidratado (15% de umidade) para gerar gás de síntese promovendo a separação do hidrogênio (H_2). Considerando a carbonização hidrotérmica seus resultados foram de 10 kg de H_2 /tonelada de lodo, comparativamente, a gaseificação por plasma gera 5,5 kg de H_2 /tonelada.

Para a carbonização hidrotérmica de lodo de esgoto, a aplicação de um catalisador ácido beneficia as propriedades das cinzas produzidas, diminuindo os teores de metais pesados, como níquel e cromo, e aumentando a proporção de fósforo. Um catalisador melhora a fertilidade do solo reduzindo o impacto ambiental (WILK *et al.*, 2023). A gaseificação por plasma com captura de carbono para lodo municipal foi avaliada na simulação do Aspen Plus por Zhang *et al.* (2023), que atingiu 50% de melhoria de eficiência energética operando em temperaturas próximas a 910°C, com uma taxa de captura de 97%.

A gaseificação do lodo de esgoto com geração combinada de calor e energia pode reduzir as emissões de dióxido de carbono (CO_2) em comparação com a combustão de gás natural. De acordo com Carotenuto *et al.* (2023) aplicado o software de simulação Aspen plus, os resultados atingiram até 2,54 kW/kg de sólidos secos, correspondendo à maior porcentagem de energia térmica, e 0,81 kW de energia elétrica. Nesse processo foi usando a temperatura de pré-aquecimento do ar de 150°C e a razão de equivalência de 0,2. Nesse experimento houve uma redução de 0,59 kg de CO_2 /kg de lodo de esgoto em comparação com a combustão de gás natural para produzir energia. O processo de gaseificação é apresentado na Figura 4.

Um novo reator de combustão de leito fluidizado circulante duplo foi avaliado por Peltola *et al.* (2023) para realizar o tratamento térmico de lodo de esgoto municipal. Os autores




Figura 4 – Processo de gaseificação.
 Fonte: Adaptado de (BURATTO *et al.*, 2024a)

verificaram que o processo é viável quando se reduz mecanicamente a umidade dessa matéria-prima com 20% até 25% de sólidos totais para reciclagem de fertilizantes, sendo autossuficiente energeticamente. Conforme Subramanian e Madejski (2023), integrando a captura de carbono pós-combustão na gaseificação de lodo de esgoto é possível alcançar emissões negativas em usinas de energia de grande escala, podendo chegar a mais de 50% das condições de carga no gás de combustão produzido.

A pirólise do lodo de esgoto pode resultar em vantagens e desvantagens. A sazonalidade contribui para o alto teor de água e uma grande concentração de carbono que beneficia os microrganismos patogênicos, entretanto, os elevados teores de nitrogênio e fósforo geram substâncias tóxicas. O controle de parâmetros na automação é importante para estabelecer soluções para tratamentos térmicos onde os benefícios superem as desvantagens de sua utilização (SLEZAK *et al.*, 2023).

2.2 ESTRATÉGIAS DE OPERAÇÃO ÓTIMA E GERENCIAMENTO TÁTICO

O despacho ideal é considerado essencial para a operação em usinas térmicas, incluindo sistemas de captura de carbono como na incineração de resíduos. Este despacho pode ser realizado ajustando a potência de saída à carga e ao tempo das tarifas, adotando mecanismos de comércio de carbono, ou reduzindo os custos operacionais, que podem ser avaliados para outros modelos de geração de lodo (ZHENG *et al.*, 2023).

Realizar a otimização na geração de eletricidade em usinas de biomassa contribui com a redução das emissões dos óxidos de nitrogênio e enxofre, aumentando o rendimento do hidrogênio usando o biocarvão produzido em pirólise (OSMAN *et al.*, 2023). Uma forma de otimização da usina é através do melhor planejamento da utilização de insumos, reduzindo o impacto da sazonalidade do sistema energético e reduzindo custos de armazenamento (REZAEI;

SAMETI; NASIRI, 2023).

Estudos têm sido realizados sobre as alternativas de despacho elétrico e a relação com sustentabilidade energética, como a certificação de carbono verde em tempo real.

Conforme avaliado por Zhu *et al.* (2023a), a aplicação dos algoritmos de aprendizagem de máquina possibilitam recuperação de carbono e energia. Em seus estudos os autores aplicaram a carbonização hidrotérmica usando lodo de esgoto municipal. Os resultados mostraram que é possível melhorar a neutralidade de carbono usando esta abordagem.

Quando é realizada a co-geração, que é o aproveitamento do calor e eletricidade em um mesmo processo, aplicar conjuntamente técnicas de identificação de dinâmicas não lineares e aprendizado profundo permite habilitar o controle e otimização em tempo real da geração. Este processo, reduz o calor desperdiçado, melhorando a eficiência energética da geração de energia (ASADZADEH; ANDERSEN, 2024).

Em uma indústria de suprimento de biocombustível a partir de biomassa, desenvolver estratégias de operação ótima e gerenciamento tático em relação aos níveis de inventários, quantidade de transporte, avaliação da capacidade de pré-processamento e armazenamento podem otimizar a biorefinaria e melhorar a eficiência da usina (TESFAMICHAEL *et al.*, 2021). Este gerenciamento pode ser realizado verificando índices de capacidades de mercado do biocombustível, integrando a localização dos compradores e avaliando a capacidade de pré-processamento e armazenamento.

Conforme Duc, Meejaroen e Nananukul (2021), modelos estocásticos e lógica Fuzzy permitem minimizar os custos totais agregados na geração por biomassa. Visando decisões táticas em uma usina de biomassa, os autores avaliaram a lógica Fuzzy considerando 11.811 variáveis, e o modelo estocástico com 35.360 variáveis. Os resultados mostraram que ao aplicar estas técnicas houve um custo otimizando do transporte e redução em emissões atmosféricas, contribuindo com a segurança energética do sistema elétrico.

Huang *et al.* (2024) propuseram um modelo de programação estocástica com dois estágios. No primeiro estágio são definidas as capacidades dos armazéns e biorefinarias; o segundo corresponde ao gerenciamento de inventário e cronograma de produção, podendo ser verificados os subsídios e os fatores de penalidade. Ao usar programação estocástica obtém-se resultados promissores na definição dos parâmetros para geração de energia elétrica, melhorando o gerenciamento do sistema.

Guo *et al.* (2022) realizaram o planejamento integrado com captura de carbono, investigando o processo de otimização na redução da emissão de gases, no transporte da cadeia de suprimento de biomassa. Com base nesta análise se realiza a determinação da eficiência de captura em cada processo na geração de eletricidade, minimizando custos de geração. A análise de sensibilidade e funções objetivos de otimização de custo de operação são avaliadas para definir o limite de velocidade de desenvolvimento, revenda e comercialização de crédito do carbono capturado.

Ao determinar metas na redução da emissão de carbono aplicando o índice de potência

Shapley-Shubik, é necessário otimizar o planejamento da cadeia de suprimento de biomassa. Conforme mostrado por Yahya, Ng e Andiappan (2021), minimizar despesas operacionais, aumentar a potência elétrica, aprimorando as rotas de transporte da biomassa e identificando o volume necessário de investimentos na descarbonização são estratégias necessárias para otimizar a geração de energia usando biomassa.

Saghaei, Ghaderi e Soleimani (2020) avaliaram qual o melhor dimensionamento de armazenamento e localização de usinas considerando a demanda nos setores de consumo. Conforme os autores, considerando incertezas na disponibilidade é possível reduzir custos em diferentes cenários avaliados usando programação linear. Esta modelagem tem como parâmetros a eficiência da usina de acordo com seu tamanho e localização, estoques de armazenamento, custos de transporte, variância no suprimento de eletricidade, e custo do tipo de material de acordo com o período que a usina está instalada.

2.2.1 Despacho Econômico em Sistemas Térmicos

A geração térmica no Brasil está aumentando de acordo com Zuin *et al.* (2023), devido a um nível mais baixo de reservatório de energia hidrelétrica, complementando assim a demanda necessária de eletricidade. Para projetos futuros, a avaliação da demanda futura é vital para determinar o potencial de aceleração e mudança para usinas térmicas, que contribuam para a redução da emissão de gases de efeito estufa com resíduos de biomassa, reduzindo os impactos ambientais e assegurando a demanda de eletricidade para a população quando ocorrerem secas.

O despacho econômico é o processo de determinar a combinação ideal de produção de energia de diferentes unidades de geração para atender à demanda de carga elétrica com o menor custo e, ao mesmo tempo, satisfazer várias restrições operacionais e do sistema (SANTOS *et al.*, 2023). A principal diferença entre a forma de despacho econômico de baixo carbono e a forma comum (ou tradicional) está na priorização das preocupações ambientais, especialmente as emissões de carbono, no processo de tomada de decisão (ZHANG *et al.*, 2022b).

Enquanto o despacho econômico tradicional visa à minimização de custos com base nos custos operacionais e de combustível, a forma de baixo carbono integra considerações ambientais, visando especificamente à redução das emissões de carbono, alinhando assim o processo de despacho com metas ambientais e de sustentabilidade mais amplas (XIANG *et al.*, 2021).

O despacho econômico de baixo carbono depende de aparelhos de conversão de energia que são relativos de acordo com a potência de troca e a carga térmica, o armazenamento e o comércio de carbono integrado com a resposta à demanda e os cenários de carga futura prevista (LONG *et al.*, 2022). Esses parâmetros podem ajudar a determinar as perdas e aumentar os mecanismos de investimento para reduzir os custos e aumentar o lucro, agregando fatores de influência para a intensidade de carbono, beneficiando a escala de tecnologias que poderiam atingir metas de emissão mais baixas em cenários futuros (LI; LUO; WEI, 2022).

A geração de eletricidade e seus custos em um sistema isolado (fora da rede) estão relacionados, predominantemente, a motores a combustível com consumo de diesel ou gás natural

(THIRUGNANAM *et al.*, 2018), principalmente porque esses tipos de energia são facilmente transportados e são fontes de energia não intermitentes, diferentemente das usinas de energia solar ou eólica (LEI *et al.*, 2020), onde existe um desafio para a previsão precisa da geração dessas fontes renováveis. Por sua vez, o combustível fóssil tem desvantagens significativas, pois gera emissões de poluentes e precisa ser refinado a partir do petróleo. No caso particular da região amazônica brasileira, este petróleo refinado é importado para então ser usado nas usinas da região (OLIVEIRA *et al.*, 2023).

A relação de interdependência entre o nexos das emissões de gases de efeito estufa, o crescimento econômico, o desenvolvimento financeiro e a demanda e oferta de carga no passado e no futuro é importante para gerenciar recomendações de políticas e/ou estabelecer estratégias para que o setor corporativo adote operações comerciais com melhores tecnologias de suporte, para melhorar o lucro com eficiência ecológica (ADEBAYO; UHUNAMURE; SHALE, 2023). Determinar cenários que possam melhorar a redução do dióxido de carbono ou coordenar sistemas de captura de carbono para atingir metas considerando incertezas e promovendo a melhor adaptabilidade possível seguindo os resultados de convergência desses quatro parâmetros foi proposto por Zhang *et al.* (2023).

Realizar a extração, a conversão e a distribuição do petróleo bruto em diesel, por sua vez, faz parte de uma cadeia energética de valor logístico que é complexa, e a inserção necessária da geração de eletricidade na rede elétrica para uma carga doméstica traz custos mais altos para o sistema elétrico em um período de curto prazo. Na tentativa de evitar essas desvantagens, a integração de fontes de energia renovável por meio da aplicação de um algoritmo de despacho ideal pode ser avaliada de forma a ajudar as empresas responsáveis a controlar as emissões de gases de efeito estufa por combustíveis fósseis. Por isso, a modelagem da previsão da capacidade de carga é essencial para planejar o escopo de energia da região analisada e a modificação da rede (AKINYEMI; MUSASA; DAVIDSON, 2022).

O despacho elétrico em sistemas de energia é determinado pela demanda do consumidor ao longo do tempo, portanto, é necessário prever o padrão de consumo de energia (TALBI *et al.*, 2020). No Brasil, o despacho do sistema de energia é baseado em um problema de otimização estocástica com horizonte de curto e longo prazo, em que a fonte de energia provém principalmente de usinas hidrelétricas (YAMASAKI *et al.*, 2024a). Nesse contexto, o preço da eletricidade é calculado com base no nível das barragens das usinas hidrelétricas usadas para regular o sistema de energia (STEFENON *et al.*, 2023).

A geração de energia elétrica através de sistemas térmicos de biomassa aproveita a energia renovável armazenada em materiais orgânicos. Esses sistemas utilizam processos de combustão ou gaseificação para converter biomassa em energia, que é então usada para criar vapor para acionar turbinas e gerar energia elétrica (POPP *et al.*, 2021). Os sistemas térmicos de biomassa oferecem uma alternativa sustentável aos combustíveis fósseis. Além disso, proporcionam oportunidades para a gestão de resíduos e a diversificação agrícola, transformando resíduos orgânicos em recursos energéticos valiosos (ASCHER; WATSON; YOU, 2022). O potencial

para prever a disponibilidade de energia nestes sistemas pode ser uma informação valiosa para a tomada de decisões, razão pela qual a previsão de séries temporais é uma solução promissora que precisa ser explorada.

Dada a necessidade de geração de energia para equilibrar a demanda de energia e garantir o preço ao longo do tempo, a geração térmica é despachada e seu valor impacta diretamente o preço do combustível usado para a geração e o preço da eletricidade repassado aos consumidores. Considerando essa necessidade, o despacho da geração térmica é uma questão importante a ser avaliada, que é o foco deste documento. Essa avaliação é ainda mais desafiadora devido à variação da estação chuvosa na região sul (BRANCO *et al.*, 2022).

Considerando esses desafios, o uso de modelos de inteligência artificial se torna uma solução promissora, considerando sua capacidade de lidar com padrões não lineares (STARKE *et al.*, 2023). As estruturas de aprendizagem profunda estão recebendo atenção para essas aplicações (SILVA; FINARDI; STEFENON, 2024; AVCI *et al.*, 2021; STEFENON *et al.*, 2024a); no entanto, elas nem sempre são a melhor abordagem, pois têm um alto esforço computacional e, em alguns casos, as redes rasas e os métodos híbridos podem ser a melhor solução (KLAAR *et al.*, 2023b).

2.3 PROCESSOS DE INCINERAÇÃO, GASEIFICAÇÃO E PIRÓLISE

As tecnologias de automação e de sensores desempenham um papel crucial na otimização e no aprimoramento de vários aspectos dos tratamentos térmicos em diferentes setores. Quando combinadas, elas permitem o controle preciso da temperatura, da pressão e de outros parâmetros críticos durante tratamentos térmicos. Isso contribui para a eficiência energética geral e a sustentabilidade nas operações de tratamento térmico (QUEIROZ; LOPES; MARTINS, 2020). Essas tecnologias são componentes integrais do paradigma da Indústria 4.0, facilitando a integração de equipamentos digitais para um ambiente de manufatura conectado e inteligente (GHOBAKHLOO, 2020). Isso inclui o uso da Internet das Coisas (IoT) (MOTLAGH *et al.*, 2020), controladores lógicos programáveis (PLCs) (SEME *et al.*, 2020) e análise de dados para criar sistemas inteligentes de tratamento térmico.

Os tratamentos termoquímicos são alternativas aos tratamentos de resíduos sólidos urbanos ou de biomassa, incluindo a combustão, a pirólise e a gaseificação, que garantem a geração de três produtos principais: eletricidade, combustíveis e calor, sendo que cada tecnologia de tratamento apresenta vantagens e desvantagens (NANDHINI *et al.*, 2022). Uma das principais diferenças entre essas tecnologias está na concentração de oxigênio na entrada, que alimenta os reatores, e produz diferentes rotas térmicas (LEDÓN *et al.*, 2016). Todas estas alternativas necessitam de diferentes tempos específicos de residência para a estabilidade do processo, resultando disso diferentes produtos gerados (KAN; STREZOV; EVANS, 2016).

Nos tratamentos de pirólise, o reator depende principalmente do tempo de residência e, portanto, tem considerável influência sobre os produtos. Através desta tecnologia pode ser produzido gás de síntese, bio-óleo e biocarvão com diferentes concentrações em reatores de

pirólise lenta, pirólise rápida e pirólise flash (SHARMA; PAREEK; ZHANG, 2015). O gás de síntese é um combustível constituído principalmente por monóxido de carbono e hidrogênio que geralmente pode ser utilizado para gerar eletricidade e/ou produção de calor. Este gás pode apresentar maior potencial energético a partir de transformações e síntese química, como por exemplo, através do processo Fischer-Tropsch, que pode transformar esse gás de síntese em gasolina, metanol, querosene ou outros derivados petroquímicos (SHARMA; CELEBI; MARÉCHAL, 2017).

As tecnologias termoquímicas utilizam principalmente três fontes de biomassa: plantas não lenhosas (plantas aquáticas e oleaginosas), plantas lenhosas (madeira) e resíduos orgânicos ou resíduos com hidrocarbonetos na sua composição (agrícolas, urbanos e agroindustriais). Em relação aos resíduos sólidos urbanos, é necessário salientar que a fração residual de plástico também faz parte desta composição constituída por hidrocarbonetos (BENATO *et al.*, 2016).

Os pré-tratamentos têm sido desenvolvidos e apresentam possibilidades de homogeneizar parâmetros importantes na biomassa que aumentam o potencial energético e elétrico. Estes parâmetros são divididos em físicos, térmicos, químicos e biológicos, e permitem que o teor de umidade, lignina e matéria mineral biológica seja variado. Estas variações ocorrem a partir de testes com diferentes tamanhos de partículas que possam alterar o rendimento equivalente e linear de gás de síntese para a produção de eletricidade (HOOGWIJK *et al.*, 2003).

Os balanços energéticos de plantas de tratamento térmico de biomassa ou resíduos sólidos por pirólise lenta em fornos rotativos têm sido aplicados em trabalhos de modelagem computacional que estudam o comportamento dos processos de tratamento de biomassa e resíduos sólidos (BABLER *et al.*, 2017). A pirólise lenta trabalha com biomassa de baixo poder calorífico, mas caso haja o pré-tratamento desta, o processo se torna autossuficiente após a inserção da biomassa (GÓMEZ *et al.*, 2016).

Tipicamente são avaliadas poucas variáveis numa única tecnologia termoquímica que são controladas por operadores. Salienta-se que existem mais de 100 parâmetros de processo para melhorar a confiabilidade e as condições para superar os desafios do processo, que são a recuperação de perdas de energia e a otimização durante sua conversão (ABOUGHALY; FATTAH, 2023).

Em centrais elétricas de pirólise lenta, existem muitas aplicações diferentes devido à versatilidade do gás de síntese, como o potencial para gerar vapor, biocombustíveis e eletricidade. É um desafio definir qual o foco, visto que, existem variações nos mercados de preços diários e mensais, além disso, há a necessidade de conceção e operação associadas à cadeia de abastecimento. Neste contexto, o foco é identificar as vias de reação mais rentáveis e sustentáveis (YUE; YOU; SNYDER, 2014).

Devido à versatilidade do combustível produzido (gás de síntese), é interessante determinar qual a aplicação que apresenta mais vantagens para uma indústria específica. Isso irá depender dos objetivos e da cadeia de abastecimento. Aplicando a otimização multiobjetivo para tornar o processo de tratamento de resíduos rentável e viável para diferentes sistemas elétricos,

pode ser uma alternativa para melhorar sua utilização (CERDA-FLORES; ROJAS-PUNZO; NÁPOLES-RIVERA, 2022).

Os materiais carbonosos da biomassa tratados por processos térmicos, como a pirólise, podem ser convertidos e têm potencial para o fabrico de nanomateriais para sensores de gás devido à sua flexibilidade química e boa condutividade eléctrica. No entanto, é necessária uma abordagem de investigação utilizando detectores portáteis para identificar as vantagens da sua possível reutilização a longo prazo, o que é benéfico quando se utilizam atualmente resíduos de biomassa, uma vez que oferece uma abordagem mais viável para o mercado (MALODE *et al.*, 2023).

O método de gaseificação de insumos renováveis para a produção de combustíveis fósseis por processos químicos com baixos níveis de oxidação em diferentes modelos de construção de reatores apresenta uma série de modos de funcionamento descritos na literatura (ZHANG *et al.*, 2023). Portanto, é necessário a verificação da aplicação de processos concomitantes de tecnologias que visam maiores rendimentos e menores emissões de poluentes (FOZER *et al.*, 2020).

Alguns resíduos, como o alcatrão, as cinzas e as partículas, são gerados na gaseificação das lamas e são dispostos em aterros sanitários. A toxicidade desses resíduos requer classes mais altas de aterros para disposição, exigindo um custo operacional mensal mais alto dos equipamentos posterior a gaseificação, o que pode inviabilizar o processo, prejudicando a eficiência ambiental e eléctrica alcançada com o aproveitamento energético do lodo (AYOL; YURDAKOS; GURGEN, 2019).

A investigação sobre a aplicação destes resíduos promove a sua viabilidade económica, transformando-os em subprodutos após a aplicação de tratamentos químicos ou biológicos. Estes tratamentos podem ser através de material adsorvente ou recuperação de fósforo. A definição dependerá do grau de investimento, da dimensão das instalações e do período de valorização esperado (ALVES *et al.*, 2021). A captura e armazenamento de carbono (CCS) apresenta o grau de evolução comercial mais aceite industrialmente (BISINELLA *et al.*, 2021). Isso se destaca, considerando que existem cerca de 1.200 instalações em funcionamento com viabilidade económica, principalmente em projetos de grande escala.

Na aplicação dos processos mais usuais a nível industrial, novas tecnologias podem contribuir para possíveis ganhos em outras características das centrais eléctricas atualmente em funcionamento (ISLAM, 2018). Esses estudos, principalmente avaliam a integração de sistemas e ferramentas de visualização em tempo real. Isto pode ocorrer, aplicando sensores no controle de processos com aprendizado de máquina, e através de pesquisas de novos materiais (WIENCHOL; SZLEK; DITARANTO, 2020).

Em países como a Áustria, Eslovénia, Alemanha, Grécia, Bélgica e os Países Baixos, as instalações de incineração são atualmente o método mais utilizado de tratamento térmico das lamas de depuração municipais. Estes são realizados em conjunto com o processo de co-incineração em centrais eléctricas que utilizam o carvão como matéria-prima nos fornos de

cimento (ALVES *et al.*, 2022).

Entretanto, a incineração reduz a eficiência da produção de eletricidade quando se utiliza a destilação criogênica, separação química do ar ou recirculação de gases combustíveis (RISSMAN *et al.*, 2020).

A seleção do reator em função das especificações da matéria-prima inserida e dos produtos desejados é um fator que determina o sucesso do processo de transformação termoquímica (RISSMAN *et al.*, 2020). Para melhorar a longevidade dos equipamentos, a monitorização das perdas através de sensores e o controle automático estão integrados na otimização do processo (RAZA *et al.*, 2021).

Após a seleção da tecnologia e dos tipos de reatores, a caracterização das amostras e o diagnóstico de controle são realizados. Isso ocorre em cada uma das categorias de captura e separação do CO₂ produzido no processo térmico, que se dividem em combustão pré-filtragem, pós-combustão e com oxigênio ou combustível e catalisadores (ATSONIOS *et al.*, 2020).

2.4 FATORES IMPORTANTES NA GERAÇÃO TÉRMICA

2.4.1 Influência da Temperatura

Em reatores de pirólise de dois estágios, a elevação das temperaturas contribui para o aumento do craqueamento térmico de sólidos e líquidos, facilitando seu posterior aproveitamento. Com os teores de hidrogênio e monóxido de carbono adequados em temperaturas a partir de 500°C, o uso de catalisadores como a dolomita calcinada pode reduzir o teor de alcatrão e produzir uma maior concentração de gás de síntese na conversão catalítica do carbono da biomassa inserida (TRABELSI *et al.*, 2021).

Em temperaturas de até 550°C, por meio de modelagem a uma taxa de aquecimento de 15°C/min, apresentam a tendência de aumentar a recuperação de energia por biocombustível, tanto de bio-óleo quanto de biocarvão. Em processos de pirólise convencionais, isso ocorre no lodo de esgoto com teores de umidade de até 15% (XU *et al.*, 2022). Além dos gases combustíveis produzidos, que são um dos principais produtos da rota de pirólise e sofrem influência direta da temperatura, as propriedades do biocarvão derivado do lodo de esgoto influenciam o aquecimento e reduzem a produção desse composto. Em temperaturas mais baixas, em torno de 300 a 400°C, o rendimento ou a concentração de biocarvão na porcentagem de produtos gerados no processo de pirólise aumenta (HOSSAIN *et al.*, 2011).

As reações de pirólise por micro-ondas são realizadas controlando a temperatura ou potência dielétrica, que começa com temperaturas de 200°C. A análise em tempo real da temperatura aumenta a eficiência na produção de biocombustíveis, e a taxa de evaporação é um parâmetro crucial no mecanismo de transferência de massa e absorção da energia consumida (LUO *et al.*, 2020).

2.4.2 Importância da Pressão Constante

Dentro dos equipamentos que realizam a oxidação do lodo em atmosferas de alta pressão, que geralmente atingem 22 a 25 MPa, existem vários desafios para viabilizar a tecnologia. Estes desafios incluem o seu elevado investimento, tempo de funcionamento e consumo de oxigênio (QIAN *et al.*, 2021). Com um equipamento antigo, há constantes incidências de corrosão que reduzem a eficiência e aumentam a mão de obra com manutenções não programadas. Além disso, existem precauções quanto à viscosidade do lodo, transportado em tubulações e com umidade elevada (YANG *et al.*, 2019).

2.4.3 Taxa de Aquecimento

No processo de pirólise, há três parâmetros principais avaliados na composição percentual dos produtos gerados, que são a taxa de aquecimento, a temperatura e o tempo de residência (DING *et al.*, 2020). Estes parâmetros são interdependentes das reações (químicas e físicas) e estão envolvidos na geometria do reator e no sistema de alimentação (CHENG; LUO; COLOSI, 2020). Fatores secundários como o tamanho das partículas e a pressão são avaliados para evitar a corrosão dos equipamentos que reduzem a sua vida útil (SHAHBEIG; NOSRATI, 2020).

2.4.4 Importância do Tempo

O tempo de reação e a taxa de aquecimento são os principais parâmetros que dividem o processo de pirólise em lento ou rápido, modificando o rendimento e os produtos gerados quando se trata das duas rotas tecnológicas mais utilizadas (JIANG *et al.*, 2021a). No entanto, a captura de dióxido de carbono em qualquer uma dessas duas rotas com a adição de diferentes catalisadores e a influência destes parâmetros ainda é desconhecida, sendo um tema de pesquisa emergente. Este fato é amplificado pela dificuldade de recuperar o composto químico aplicado como catalisador e dos seus mecanismos diferirem consoante a sua afetação *in situ* ou *ex-situ*. A partir deste segundo modo, é recuperado mais facilmente, uma vez que o catalisador não se mistura dentro do reator principal de pirólise, promovendo uma maior filtração (SUN *et al.*, 2022).

Uma reação que tem duas matérias-primas inseridas no reator é chamada de co-pirólise. Esta reação forma produtos orgânicos e água, e após a reforma do vapor, se produz hidrogênio livre como combustível gasoso, principalmente na pirólise lenta (GOUWS *et al.*, 2021). A redução da taxa de carbono e oxigênio na biomassa depende do tempo de reação, que afeta as propriedades e o rendimento dos produtos gerados no processo de pirólise (AMENAGHAWON *et al.*, 2021). O desempenho e as interferências na captura de carbono nas diversas tecnologias que estão sendo investigadas são desconhecidas e, recentemente, têm sido aplicadas a nível industrial e experimental (KETOV *et al.*, 2022).

2.5 AUTOMAÇÃO E IA NOS PROCESSOS TÉRMICOS

Modelos como o aprendizado de máquina são alternativas para automação de plantas de geração térmica. A homogeneidade da matéria-prima quando se trata de lodo de esgoto municipal, contribui para a análise do consumo de energia em sistemas multi-dinâmicos que combinam o uso de calor e energia elétrica além de possibilitar a previsão de melhorias de desempenho. Isso significa, maior eficiência energética a partir de um extenso banco de dados de correlações entre os parâmetros de atendimento às normas ambientais locais (OLAFASAKIN *et al.*, 2021).

Um dos fatores preponderantes na elevação da capacidade de otimização na produção de compostos através de qualquer biomassa é a qualidade dos dados. Quanto maior a homogeneidade das características nos equipamentos utilizados e metodologia similar aplicada, melhor será a qualidade dos dados. Porém, estas tecnologias requerem uma extensa base de dados a partir do avanço na implantação da indústria 4.0 (VELIDANDI *et al.*, 2023).

Implementar uma interface conjunta com linguagens de programação para sistemas de controle e aquisição de dados, e software simulador de cinética térmica, química e elétrica, pode ser uma solução para melhorar a eficiência do processo de geração. No entanto, devem ser observados os custos de implementação e manutenção do armazenamento desta base de dados e os custos recorrentes de subscrição de serviços na nuvem (DEON *et al.*, 2022).

No contexto das aplicações de automatização, existem vários modelos que são adotados conforme o grau de controle desejado. Existem vários modelos que podem causar variabilidade, de acordo com a estratégia, que pode ser adaptativa, preditiva, inteligente e coordenada automaticamente (ALVES *et al.*, 2021). Estes modelos são dependentes dos investimentos que podem ser realizados, dos requisitos necessários e de possível manipulação das variáveis operacionais. As configurações do processo são em função da capacidade, tamanho, tipo de material a ser processado e produtos. Essas dependem dos objetivos da geração e são determinantes conforme a capacidade financeira do projeto (ATSONIOS *et al.*, 2020).

Quando a automação é aplicada após a realização de vários testes e com um diagnóstico de controle eficiente, permite-se a expansão e o escalonamento da operação das usinas. Este escalonamento, por sua vez, ocorre de forma mais eficiente, sendo necessário um nível de instrução técnica menor para sua implementação, em comparação com sistemas não automatizados e operados manualmente. Isto evita a maior probabilidade de erros humanos, proporcionando maior segurança operacional (MONTAGNARO *et al.*, 2018).

2.5.1 Monitoramento no Tratamento Térmico de Resíduos

A geração de energia elétrica a partir da energia térmica envolve a conversão de energia térmica em energia elétrica, e esta conversão depende de vários recursos para uma operação eficiente. Um dos recursos mais importantes é haver uma fonte de calor adequada. Para uma fonte de calor consistente e confiável, como combustíveis fósseis (carvão, gás natural) ou

fontes renováveis, como biomassa, é fundamental a integração dos sistemas de resfriamento eficazes, pois evitam o superaquecimento e mantêm a eficiência operacional. Geralmente são usados métodos de resfriamento a água ou a ar para manter a temperatura adequada. Além disso, algoritmos de controle e sistemas de monitoramento podem auxiliar na regulação da temperatura (GUELPA; VERDA, 2019).

2.5.2 Sensores em Termoelétricas

Os dados dos sensores em uma interface de controle com gráficos e dados históricos, disponibilizam relatórios que podem fornecer informações que auxiliam na lógica de acionamento, diagnosticando e prevendo possíveis falhas (LEEUW; KOELEMMEIJER, 2022). Estes sensores, podem minimizar a possibilidade de paradas súbitas do processo, limitando assim a formação de poluentes atmosféricos (LU *et al.*, 2020). O controle automático permite maximizar os benefícios económicos e a melhoria da segurança do processo, possibilitando maior garantia na redução dos poluentes gerados no sistema (KROCHMALNY *et al.*, 2020).

A interface de controle para estes sistemas pode ser baseada em interfaces homem-máquina, interfaces gráficas de utilizador, sistemas de monitoramento ou sistemas de controle de supervisão e aquisição de dados. Estas interfaces têm por objetivo apresentar ou receber informação de uma forma amigável para o utilizador. Isto facilita as atualizações, as medições e os controles necessários nos sistemas industriais (KUMAR; LEE, 2022). Tipicamente, as plataformas que efetuam a análise e o processamento de dados geram melhorias no desempenho dos processos térmicos através do aumento do poder calorífico do gás de síntese, que aumenta a geração de energia eléctrica (KABUGO *et al.*, 2020).

A calibração dos sensores permite a medição e o controle através da criação de alarmes e da detecção de escalas ótimas. Isto pode beneficiar mecanismos de captura e filtragem do volume de gases nocivos, que podem proporcionar ajustes automáticos no sistema de alimentação, especialmente se houver uma utilização recorrente de bombas centrífugas nesta operação (AVILÉS; VELÁZQUEZ; RIQUELME, 2019).

2.5.3 Previsão de Séries Temporais Usando IA

A melhoria da qualidade e confiabilidade de redes de energia eléctrica através da aplicação de inteligência artificial (IA) representa um salto transformador na gestão moderna dessas redes (STEFENON *et al.*, 2024b). Algoritmos de IA, como ML e redes neurais profundas, analisam registros históricos para identificar padrões e anomalias na rede de energia eléctrica (SEMAN *et al.*, 2023), prevendo falhas de equipamentos, otimizando a distribuição e detectando possíveis distúrbios (STEFENON *et al.*, 2023). A manutenção preditiva baseada em IA minimiza o tempo de inatividade, reduz os custos do setor e estende a vida útil dos componentes críticos da infraestrutura. O monitoramento e controle do sistema de energia eléctrica por IA permite mitigar o impacto de interrupções e flutuações de tensão, garantindo um fornecimento de energia

consistente e de alta qualidade aos consumidores. O uso de métodos de IA têm sido destacado, principalmente, no que diz respeito à previsão (YAMASAKI *et al.*, 2024b).

O uso de séries temporais para previsão de energia elétrica envolve a previsão do consumo ou da produção futura de energia com base em padrões de dados históricos (STEFENON *et al.*, 2023a). Os métodos usados para a previsão de energia elétrica são semelhantes às técnicas gerais de previsão de séries temporais, mas são adaptados para abordar as características específicas dos dados relacionados à energia elétrica. A seleção do modelo correto envolve a compreensão das características dos dados, o teste de várias abordagens e a avaliação do desempenho do modelo usando métricas apropriadas (SEMAN *et al.*, 2023).

A previsão de séries temporais em sistemas de energia é promissora para prever a demanda futura de electricidade e os padrões de produção, permitindo às empresas eléctricas gerir eficazmente os seus recursos e manter a estabilidade da rede. Ao analisar dados históricos sobre fatores como condições meteorológicas, tendências económicas e consumo de energia passado, os modelos de séries temporais podem prever a procura de carga futura. Essas previsões são essenciais para otimizar cronogramas de produção, planejar atividades de manutenção e tomar decisões informadas sobre investimentos em infraestrutura (SILVA; FINARDI; STEFENON, 2024). Esta abordagem é importante na integração de fontes de energia renováveis, como a energia solar e eólica, na rede, prevendo a sua produção variável. Técnicas avançadas, como algoritmos de ML e redes neurais, são cada vez mais utilizadas para aumentar a precisão e robustez dessas previsões, garantindo a operação confiável e eficiente dos sistemas de energia elétrica (STEFENON *et al.*, 2024a).

No trabalho de Safarian *et al.* (2020a) é apresentada uma RNA com uma abordagem de equilíbrio termodinâmico para gaseificação de biomassa *downdraft* com unidades de geração de energia. As entradas do modelo abrangem composições de análise elementar, composições de análise centesimal, juntamente com parâmetros operacionais. Dados de treinamento compreendendo 1.032 entradas simuladas derivadas de 86 tipos distintos de biomassa em várias condições operacionais foram utilizados para treinar a RNA. A RNA desenvolvida demonstra forte concordância com os dados simulados, alcançando uma fração absoluta de variância superior a 0,999 para previsão de potência do produto. O modelo integrado baseado em RNA proposto possui um potencial significativo como uma ferramenta prática para otimizar e controlar a gaseificação de biomassa com unidades de geração de energia.

Vários trabalhos apresentam propostas interessantes para a aplicação de modelos de IA, mas ter dados representativos pode ser um desafio (AKINPELU *et al.*, 2023). Uma base de dados que pode ser destacada é apresentada em (SAFARIAN *et al.*, 2020b), onde o conjunto de dados compreende experimentos conduzidos em um gaseificador de biomassa ligado a uma unidade de produção de energia. Melhorar a previsão por meio da fusão sinérgica de ML, análise espectral singular (SSA) e decomposição de modo variacional (VMD) representa um avanço significativo na previsão de energia renovável. Ao amalgamar essas técnicas, surge uma abordagem abrangente, capaz de capturar padrões espaço-temporais complexos inerentes aos

dados de vento (MORENO *et al.*, 2024).

Algoritmos de ML, incluindo modelos DL, podem discernir relacionamentos complexos dentro dos dados, facilitando previsões precisas (KLAAR *et al.*, 2023a). Segundo Moreno *et al.* (2024) SSA auxilia na decomposição da série temporal em componentes interpretáveis, enquanto o VMD aprimora o processo de decomposição, fornecendo adaptabilidade a sinais não estacionários. A integração destas metodologias permite uma compreensão holística do comportamento do vento, resultando em previsões refinadas, cruciais para otimizar a geração de energia eólica e a gestão da rede.

Na análise de séries temporais, a decomposição de altas frequências refere-se ao processo de decomposição dos dados em seus componentes constituintes, concentrando-se particularmente nas rápidas flutuações ou variações que ocorrem em frequências mais altas dentro da série temporal (STEFENON *et al.*, 2021). Esses componentes de alta frequência geralmente representam flutuações ou ruídos de curto prazo nos dados que podem obscurecer padrões ou tendências subjacentes (BRANCO *et al.*, 2022). Pela eliminação de ruído de séries temporais, altas frequências podem ser eliminadas e inúmeras técnicas podem ser usadas, como análise de Fourier, filtro Savitzky-Golay (GUO *et al.*, 2023), decomposição wavelet (STEFENON *et al.*, 2023), transformada wavelet empírica (EWT) (LU *et al.*, 2023), VDM (RIBEIRO *et al.*, 2024), filtro adaptativo de kernel (SHI *et al.*, 2023a) ou filtro Hodrick–Prescott (IFTIKHAR *et al.*, 2023). A decomposição e remoção de ruído auxiliam na melhor compreensão da estrutura e dinâmica subjacentes das séries temporais, facilitando previsões e tomadas de decisão mais precisas em vários domínios (STEFENON *et al.*, 2023b).

Atualmente, os modelos LSTM combinados com técnicas de decomposição vêm ganhando espaço na previsão de energia e têm sido aplicados por diversos autores. Além dos modelos LSTM padrão, alguns pesquisadores estão avaliando unidade recorrente fechada (GRU), média móvel integrada autoregressiva (ARIMA), LSTM bidirecional (BiLSTM), redes convolucionais temporais (TCN), dados de série temporal sequência a sequência (Seq2Seq), entre outras variações que se mostram promissoras neste campo. Mesmo o modelo ARIMA sazonal (SARIMA) pode ser aplicado a este respeito para melhorar as previsões.

Previsão de rendimento agrícola usando CNN-LSTM avaliada por Nejad *et al.* (2022) mostrou algumas vantagens como diminuição da complexidade da rede porém, suas limitações ocorreram devido às limitações de software e hardware para processar as imagens de sensoriamento remoto com informações de dados de alta dimensão, conseqüentemente, fornecendo configuração espacial-espectral e verificando maior resolução nas imagens e ajuste hiperparâmetros para reduzir erros na previsão.

Em relação à estimativa de biomassa, Kijo-Kleczkowska *et al.* (2024) investigou o impacto de vários fluidos básicos nas propriedades de transferência de calor convectiva dentro de coletores solares utilizando nanofluidos. Os pesquisadores analisaram como diferentes fluidos básicos, incluindo água, etilenoglicol e óleo, influenciaram a condutividade térmica e a eficiência geral dos sistemas de energia solar quando combinados com nanopartículas. As descobertas

do estudo destacaram o papel significativo que a seleção de fluidos básicos desempenhou na otimização do desempenho do coletor solar, sugerindo que fluidos básicos específicos poderiam ser adaptados para melhorar a captura e transferência de energia.

Lee, Choi e Hwang (2024) apresentaram um estudo de ML aplicado na pesquisa de biopetróleo. Segundo eles, os métodos de regressão são os mais comumente usados para construir modelos preditivos, sendo as cinco principais técnicas de ML: floresta aleatória, redes neurais artificiais, aumento de gradiente, regressão de vetores de suporte e regressão linear. A pesquisa atual enfrenta desafios como disponibilidade limitada de dados, extração de recursos com base no conhecimento do domínio e uso restrito de ML.

Samadi, Ghobadian e Nosrati (2020) avaliaram a energia da biomassa de resíduos agrícolas e, com base em um modelo de equilíbrio estequiométrico, alcançaram um RMSE de 0,571 a 1,10. Considerando esses resultados, os autores mostraram quão alta pode ser a capacidade de geração de energia a partir de resíduos agrícolas.

No trabalho de Klaar *et al.* (2023a), uma sequência dupla é considerada para a avaliação de séries temporais. Eles destacam como a transformação wavelet pode ser usada para reduzir o ruído do sinal e aprimorar as previsões usando uma série temporal filtrada. O mecanismo de atenção permite que o modelo se concentre em partes específicas da sequência de entrada ao fazer previsões, dando mais peso ou importância a determinadas etapas de tempo ou recursos.

Nanditha e Mishra (2021) aplicaram métodos de aprendizado de conjunto para estudar os fluxos dos rios na Índia. A preocupação em relação ao influxo são as enchentes e por isso a previsão da afluência natural é consideravelmente importante neste contexto. A ideia da previsão de afluência considerando as enchentes é equivalente às informações necessárias para as usinas hidrelétricas, mostrando que a abordagem pode ser usada para outras aplicações.

Com foco na previsão de despacho de geração térmica, Finkenrath *et al.* (2022), aplicando uma abordagem baseada em aprendizado de máquina, realizaram a previsão de carga térmica para um horizonte de 72 horas. Eles mostraram que, usando o aprendizado de máquina, é possível otimizar o despacho de sistemas de geração térmica, melhorando a eficiência do sistema. A avaliação dos sistemas térmicos considerando a *Facebook Prophet*, *Neural Prophet* e LSTM foi discutida no trabalho de Kahwash, Barakat e Maheri (2023).

O ANFIS é um modelo híbrido que combina os recursos adaptativos das redes neurais com a interpretabilidade da lógica difusa. Ele tem sido amplamente utilizado para a previsão de séries temporais devido à sua capacidade de modelar relações complexas e não lineares nos dados. O modelo ANFIS consiste em uma série de nós interconectados organizados em camadas (FATEMI; PARVINI, 2022).

Na estrutura do ANFIS, a camada de fuzzificação mapeia as variáveis de entrada para conjuntos fuzzy. Cada nó dessa camada representa uma função de associação para um conjunto fuzzy específico. A camada de regras calcula a força de disparo de cada regra combinando as associações fuzzy das variáveis de entrada. A camada de consequências calcula a consequência de cada regra. Normalmente, ela envolve uma combinação linear das variáveis de entrada. A camada

de saída agrega as saídas da camada consequente para produzir a previsão final (STEFENON *et al.*, 2021).

Os parâmetros dos conjuntos fuzzy e da camada consequente são adaptados durante o processo de treinamento. O treinamento do ANFIS envolve um algoritmo de aprendizado híbrido que combina descida de gradiente e mínimos quadrados recursivos. O modelo é treinado em dados históricos de séries temporais, ajustando suas associações difusas e parâmetros consequentes para minimizar uma função objetiva escolhida (PUSTY *et al.*, 2024). O ANFIS oferece uma estrutura flexível para modelar dados de séries temporais. Sua capacidade de capturar relações não lineares e de se adaptar a padrões variáveis o torna uma ferramenta valiosa em várias tarefas de previsão de séries temporais.

Branco, Cavalca e Ovejero (2024) verificaram a aplicação do filtro de passeio aleatório de Cristiano Fitzgerald para a previsão de falhas em sistemas de energia, avaliando uma comparação entre os modelos de aprendizado de conjunto de agregação *bootstrap*, *boosting*, subespaço aleatório e generalização empilhada e determinando que as abordagens de conjunto são uma estratégia promissora. O tempo de processamento do LSTM com filtro foi mais rápido do que sem ele, no entanto, observou que a implementação bem-sucedida depende principalmente da seleção do modelo e da qualidade dos dados, e sua pesquisa concluiu que o aprendizado em conjunto supera os modelos LSTM e ANFIS.

De acordo com Neto *et al.* (2022), vários modelos podem ser aplicados e é difícil definir qual método é mais adequado para uma aplicação específica. Nesse caso, a melhor estratégia é avaliar o maior número possível de técnicas para definir a melhor abordagem para a aplicação. Conforme Souza *et al.* (2023), um dos principais objetivos desse tópico é a garantia do fornecimento de energia.

A confiabilidade da rede elétrica é importante para os consumidores e é o objetivo dos fornecedores de serviços de eletricidade (CORSO *et al.*, 2021). Além da previsão de carga, a confiabilidade da rede de energia elétrica tem sido avaliada (STEFENON *et al.*, 2022), especialmente usando métodos de aprendizagem profunda, como redes neurais convolucionais (CNNs) (CORSO *et al.*, 2023), ou mesmo métodos híbridos (STEFENON *et al.*, 2022) que combinam CNNs com outros modelos (STEFENON *et al.*, 2023). Com foco em séries temporais, o uso de métodos híbridos de aprendizagem profunda tem se mostrado promissor conforme apresentado por Kasburg e Stefenon (2019).

De acordo com Klaar *et al.* (2023b), a energia tem um impacto social importante e sua previsão pode ajudar no cenário de tomada de decisões políticas. Em sua pesquisa, um método de aprendizado de conjunto foi combinado com abordagens de decomposição sazonal para prever o preço da energia no México. Ao otimizar os modelos usando uma abordagem de hipertensão, é possível obter um erro quadrático médio de $3,37 \times 10^{-9}$, que foi menor do que outros modelos de última geração.

Ribeiro *et al.* (2020a) avaliaram o preço da eletricidade do Brasil usando uma abordagem de aprendizagem autoadaptativa, heterogênea, decomposta e de conjunto. Eles provaram que,

usando um método híbrido, é possível ter um erro percentual absoluto médio 4,2% menor do que outros métodos. Em seu método, vários modelos são avaliados e combinados para criar uma estrutura que supere os modelos individuais.

Considerando o uso de métodos híbridos em que são aplicados filtros de redução de ruído, em (STEFENON *et al.*, 2023b) o método de grupo de manipulação de dados foi combinado com o filtro de passeio aleatório Christiano-Fitzgerald para previsão de falhas. Com um erro quadrático médio de $3,44 \times 10^{-12}$, o método superou o modelo padrão (sem o filtro) e o LSTM.

Uma combinação de diferentes métodos de inteligência artificial de previsão de carga elétrica pode fornecer a mais alta precisão, evitando o excesso de ajuste e beneficiando a resolução de extração de recursos. Os modelos híbridos da aplicação de otimização estocástica como LSTM e wavelet geralmente têm a capacidade de processar dados sequenciais mais rapidamente do que os algoritmos simples (CHANG; ZHANG; CHEN, 2019), permitindo encontrar um conjunto de pesos adequados e redes neurais recorrentes ajudando a calibrar o tempo de previsão (KIM *et al.*, 2019).

O LSTM tem vantagens para séries temporais longas e, combinado com o mecanismo de atenção, pode ser um poderoso mecanismo de previsão de séries temporais. O LSTM, considerando um problema de sequência a sequência, foi usado para a previsão de níveis de água por Stefenon *et al.* (2023). Os autores provaram que esse método pode ser ainda melhor quando combinado com a transformada wavelet. Considerando um erro quadrático médio de 0,0020, seu método foi melhor do que outros modelos bem estabelecidos.

2.6 COMBUSTÍVEIS E PRODUTOS DERIVADOS PARA ÁREA ELÉTRICA

2.6.1 Gás de síntese na geração de eletricidade

O gás de síntese ou syngas é um combustível constituído principalmente de monóxido de carbono e hidrogênio que pode ser usado para geração de eletricidade e/ou calor. Este tem o potencial energético para transformações a partir da síntese química, podendo ser utilizado pelo processo de Fischer-Tropsch para produzir gasolina, metanol, querosene e outros derivados petroquímicos (SHARMA; CELEBI; MARÉCHAL, 2017).

A recuperação de energia com o looping químico de gás de síntese é uma estratégia importante que alcança resíduos sólidos municipais ou biomassa de tratamentos térmicos ou biológicos. Essa solução consiste no gás de alimentação de ciclos de turbina a vapor, que é uma alternativa viável para o biogás que fornece digestão anaeróbica ou gás de síntese gerado por tratamentos térmicos, como pirólise ou gaseificação, que podem produzir combustíveis em uma biorrefinaria ou geração de eletricidade (DARMAWAN *et al.*, 2018).

Considerando a gaseificação aprimorada por sorção de lodo de esgoto seco em uma instalação solar, Moles *et al.* (2024) obteve um gás de síntese com 70-73%vol de H₂ e baixos teores de CO e CO₂ com 2-3 %vol e 8%vol. O potencial de biomassa para gerar eletricidade por meio de gás de síntese no Rio Grande do Sul com as indústrias de arroz em Pelotas representa

uma capacidade de 7,7 MWh utilizando a casca de arroz e os efluentes. Esse potencial poderia tornar essas indústrias autossuficientes (SILVEIRA *et al.*, 2019).

Nas usinas de energia por pirólise lenta, são usadas muitas abordagens diferentes devido à versatilidade do gás de síntese, como o potencial de geração de vapor, biocombustíveis e eletricidade. Essas aplicações geralmente entram em conflito simultaneamente com os mercados de preços e com a necessidade diária ou mensal de projeto e operação associados à cadeia de suprimentos, identificando os caminhos de reação mais econômicos e sustentáveis no processo (YUE; YOU; SNYDER, 2014).

A versatilidade desse combustível (gás de síntese) produzido é interessante para determinar qual aplicação apresenta mais vantagens para determinado setor, dependendo do objetivo e de sua cadeia de suprimentos. Inclusive é possível aplicar a otimização multiobjetivo para tornar o processo de tratamento de resíduos economicamente viável para diferentes sistemas elétricos (CERDA-FLORES; ROJAS-PUNZO; NÁPOLES-RIVERA, 2022).

A fonte de energia para a remoção de dióxido de carbono precisa ser de baixo carbono ou livre de carbono, para gerar energia para o processo. Para obter uma dessas soluções, ainda mais promissora, é possível integrar múltiplas tecnologias, usando a captura direta de ar integrada à bioenergia com captura e armazenamento de carbono. Este processo fornece os requisitos de energia térmica e elétrica, principalmente, usando a recuperação de calor durante o resfriamento do gás de síntese nos processos de gaseificação e pirólise (OKONKWO *et al.*, 2023).

O ciclo Rankine para sistemas de pirólise a partir do gás de síntese para produzir vapor pode alocar três estágios: primeiro, uma turbina de alta pressão, seguida de uma expansão sequencial por turbinas de média e baixa pressão, maximizando a recuperação de energia. A recuperação do calor do vapor para geração adicional de energia é outro fator vital para a otimização de usinas de pirólise (HU *et al.*, 2025).

Na gaseificação ou pirólise, é possível aplicar ciclos Rankine e Brayton integrados para dessalinização e reciclagem de dióxido de carbono, usando o gás de exaustão da turbina no ciclo Brayton que o gás de síntese como recurso químico convertido em energia mecânica e depois elétrica com o potencial de recuperar o calor para produzir vapor como ciclo Rankine que fornece destilação de multiefeito com compressão de vapor térmico e um processo de pós-combustão com captura de carbono (AKBARI; KHALILARYA, 2026).

2.6.2 Biocarvão na produção de super capacitores

O biocarvão é um material com versatilidade para fins comerciais (AWOGBEMI; KALLON, 2023), e sua transformação por meio de métodos laboratoriais com dopagem mineral é uma ótima alternativa para aumentar seu valor econômico sobre os subprodutos produzidos na biorrefinaria (CHOI *et al.*, 2024).

Conforme avaliado por Yuan *et al.* (2024), o principal desafio dos materiais de carbono derivados da biomassa para supercapacitores é o custo de produção e a faixa de temperatura dos materiais do eletrodo. Os supercapacitores derivados de resíduos de biomassa com uma

densidade de energia inferior a 10 Wh/kg restringem as suas aplicações práticas (WANG *et al.*, 2023b)

Algumas estratégias de ativação aplicam produtos químicos perigosos, como hidróxido de potássio e hidróxido de sódio, que poderiam ser substituídos por heteroátomos ambientalmente corretos, que melhoram as técnicas de hidrofília e grafitização da superfície. De acordo com Rawat *et al.* (2023), isso auxilia na redução do custo do biocarvão de alta qualidade e permite alcançar a estrutura dominante de microporos, necessária para o armazenamento de hidrogênio.

Sahu *et al.* (2023) verificou que os microporos (<2nm) têm desempenho superior em comparação com os mesoporos (2-50 nanômetros). O material de carbono precisa de uma alta área de superfície (2000-3000 m²/g) e tamanho de poro de 2-5 nanômetros, para obter uma faixa de energia de 1-10Wh/kg e uma faixa de potência de 500 a 10 mil W/kg.

Outro fator importante na industrialização de supercapacitores a partir da pirólise de biomassa é o desempenho de energia volumétrica que depende de uma área de superfície específica. Yang *et al.* (2023) sugeriu recomendações no processo de produção como utilização de nanopartículas de hidróxido de carga, polímeros condutores ou óxido de metal, para gerar uma camada dupla elétrica e levar à capacitância máxima com ciclo de vida longo.

A economia circular pode ser alcançada quando se melhora o biochar à base de lodo. Essa melhoria ocorre com conteúdo rico em nitrogênio, carbono e estruturas grafíticas. Conforme Mian *et al.* (2022) isso pode ser realizado regenerando locais eletroquimicamente ativos usando gás reativo como amônia em pirólise ambiental, obtendo maior área de superfície em baixa temperatura. Os principais desafios da produção de carbono poroso hierárquico, que é um material atraente para o armazenamento de energia, foram apresentados em uma revisão feita por Cuong *et al.* (2021). O autores compararam diversos resíduos de biomassa e descobriram as limitações que são a alta recuperação de água, a capacidade de eletrossorção e o método de dessalinização eficiente.

O material de carbono poroso fornecido por fontes de lodo de esgoto municipal é eficaz como material de eletrodo, especialmente na remoção de ácido húmico, que é um material de óxido de grafeno. Este inibe a eficiência metanogênica na digestão anaeróbica, mas que apresenta aplicações potenciais como carbono ativado usando ativação química de hidróxido de potássio (GUO *et al.*, 2023).

Li *et al.* (2023a) avaliaram em experimentos de laboratório que a capacitância específica do ácido húmico derivado do lodo de esgoto municipal pode ser melhorada quando é condensada pela membrana de ultrafiltração. Isso ocorre com um aumento de quase 18 até 35%, obtendo em uma descarga de carga galvanostática a capacitância específica mais alta de 186,7 Faraday/grama em uma densidade de corrente de 0,05 Ampere/grama. De acordo com os autores, isso é comparável à do ácido húmico originado do carvão ou de produtos comerciais de ácido húmico.

A instabilidade das propriedades e a difícil repetibilidade das condições de síntese da técnica de fabricação vista por Chen, Wang e Wang (2024) são os grandes obstáculos apresentados na introdução da fabricação em larga escala de materiais de carbono derivados de resíduos de

biomassa para aplicações de supercapacitores em dispositivos eletrônicos portáteis e no campo aeroespacial, e na exploração do aprimoramento dos fatores críticos do mecanismo de formação de carbono.

O método de preparação e seu controle preciso da estrutura hierárquica dos poros precisam melhorar e resolver a conexão e distribuição dos tamanhos dos poros em conformidade com Zhang *et al.* (2023), concluindo que as impurezas são obstáculos e exigem a remoção do enxágue ou lixiviação aplicando custos possíveis mais baixos do que os atuais alcançados, transformando grupos funcionais de heteroátomos prejudiciais que aumentam os defeitos e a molhabilidade com estratégias de inovação viáveis que exigem muita pesquisa para produzir um supercapacitor com rendimento e melhorando o ciclo de vida dos materiais de eletrodo.

A falta de homogeneidade e os métodos de descontrole aleatórios na transformação térmica da biomassa para produzir carvão ativado resultam em baixo desempenho e reduzem a probabilidade e a lucratividade da produção de aplicações em larga escala. A maior parte da pesquisa na literatura, conforme avaliada por Lin *et al.* (2022), concentra-se apenas no aumento da área de superfície específica como a maior capacitância, ignorando os métodos de controle do processo de geração de biochar.

A reutilização, a estabilidade e o pós-tratamento do biochar usado para produzir supercapacitores precisam de mais pesquisas futuras, conforme revisado por Almeida *et al.* (2020), a fim de fornecer plantas em larga escala aplicadas na comercialização de material para dispositivos de armazenamento.

Planejar o escopo das condições ideais dos procedimentos de produção e estruturar a composição da biomassa é essencial para projetar nanoestruturas de acordo com Manasa, Sambasivam e Ran (2022), pois aumenta o conhecimento da inter-relação entre a química da superfície, o tamanho dos poros e a área de superfície da biomassa analisada.

O potencial comercial do carvão ativado de resíduos de biomassa usado como supercapacitor depende da orientação sobre sustentabilidade e de considerações sobre fontes renováveis com impactos ambientais e custo-benefício dependendo de cada biomassa, inclusive em leis regulamentadas que aumentem a competitividade acrescentando a otimização de equipamentos como a automação da produção para competir em relação ao preço atribuído juntamente com a qualidade do carvão ativado convencional vendido atualmente, identificando nichos ou aplicações em que esses tipos de carvão ativado têm melhor comportamento eletroquímico devido a suas propriedades exclusivas, conforme avaliado por Adeniyi *et al.* (2023).

2.6.3 Amônia Verde na Geração de Energia Elétrica

A produção sustentável de amônia a partir da biomassa é importante para reduzir a emissão de dióxido de carbono da amônia produzida por combustíveis fósseis. Avaliando esse procedimento, Garcia *et al.* (2024) verificou com a simulação no software AVEVA Pro 2 e experimentos de laboratório, que a pirólise de biomassa e o processo de reforma de vapor de ar em linha são estratégias potenciais para obter essa amônia verde. Usando serragem de pinheiro

como matéria-prima em sua pesquisa, foi estimado cerca de 558 g de amônia por kg dessa biomassa.

A recuperação de nitrogênio é outra opção tecnológica para produzir amônia a partir de biocarvão produzido com lodo de esgoto e de acácia negra invasiva a partir da pirólise, apresentando um custo de energia menor do que o processo convencional Haber-Bosch, conforme declarado por Beckinghausen *et al.* (2020), apesar de requerer uma ativação química significativa neste biocarvão para a adsorção de amônia, devendo ser realizado uma análise técnico-econômica de acordo com o processo analisado.

A correlação entre a energia interna consumida na estação de tratamento de esgoto e o potencial de recuperação de energia pode ser realizada por meio de modelagem computacional, avaliando a remoção de poluentes e apresentando se há melhorias na inserção e conjugação de novas rotas tecnológicas. Um dos principais desafios para a produção de hidrogênio a partir de lodo de esgoto ainda é o menor rendimento e taxa de produção tanto em processos biológicos quanto em tecnologias térmicas com possibilidades de aumentar ambas as técnicas com pesquisas de dosagem de nanopartículas. Esse aspecto deve ser avaliado incluindo a participação e influência de cada material aplicado em uma rota catalisadora para microrganismos ou participação química como concluído por Khan *et al.* (2024).

Devido ao baixo custo de armazenamento e transporte da amônia verde, tendo a possibilidade de ser uma rota de despacho sustentável de energia e eletricidade com a facilidade dos combustíveis fósseis atuais a partir de recursos renováveis, sendo verificado por modelagem de previsão por Cesaro *et al.* (CESARO *et al.*, 2021) que estará entre os valores de 300 até 400 dólares por tonelada em algumas localizações, e por otimização de eletrolisadores em 2040, competindo com gás natural e bio-energia no despacho elétrico.

O impacto exercido da produção e utilização de amônia verde em relação a cada um dos dezessete objetivos do desenvolvimento sustentável foi avaliado em baixo, moderado, alto, muito alto por Sekhar *et al.* (SEKHAR *et al.*, 2024) que determinou isto a partir de uma revisão sistemática e verificando os principais desafios tecnológicos da introdução dessa geração de amônia verde. Os autores concluem como principais desafios a dificuldade de separar componentes não reagidos e produzir em circunstâncias de baixa pressão.

2.7 DESCARBONIZAÇÃO NA GERAÇÃO TERMOELÉTRICA COM LODO

A remoção dos poluentes provenientes da oxidação do carbono, que pode ocorrer nos processos de geração de energia elétrica (também chamada de descarbonização), através da aplicação de tecnologias como a captura e armazenamento de carbono (CCS) tem diferentes vertentes de desenvolvimento tecnológico e científico sendo pesquisadas ao nível da avaliação de configurações construtivas e controle das variáveis físicas e químicas dos reatores nos processos térmicos como pirólise/gaseificação com simulações. No processo de descarbonização, o CO₂ é convertido em CO, que é um gás de combustão inflamável. Para produzir outro insumo

econômico com temperatura de reforma e vapor, precisa melhorar em plantas de grande escala, mas ainda não se sabe se o H₂ diminuiu muito nesta operação de gaseificação/pirólise. No entanto, este balanço muda de composição mol% do CO₂ depois de capturado e reciclado (CHAI; PACKHAM; WANG, 2022).

Alcançar uma transição energética realista depende do estabelecimento de uma via em que os combustíveis de energia densa sejam importantes para os padrões econômicos da civilização global, uma vez que as alterações climáticas são uma prioridade (CLOETE *et al.*, 2023). Os campos de águas residuais são responsáveis por até 7% do metano e 10% do óxido de nitrogênio decorrentes de emissões humanas, representando 60% deste derivado proveniente dos processos e 30% de contribuição indireta relacionada à energia. A descarbonização pode ser alcançada através de rotas de otimização sobre o uso de produtos químicos e transporte (MAKTABIFARD *et al.*, 2023).

Chu *et al.* (2024) realizou uma pesquisa sobre a viabilidade da neutralidade de carbono na indústria de tratamento de lodo e os seus resultados mostraram que a previsão realista atingirá 30.291,65 kt CO₂ em 2030, em que a possibilidade otimizada depende da melhoria do processo de secagem para estabelecer 5816,19 kt CO₂ neste mesmo ano de projeção. Os principais obstáculos aos transportes limpos são o planejamento financeiro para a procura a longo prazo, a aceitação social e a disponibilidade para pagar preços mais elevados pelos combustíveis alternativos até se atingir uma produção melhorada em matéria de investigação e desenvolvimento, a estabilidade regulamentar, bem como o investimento na tecnologia de captação direta do ar em instalações de produção e armazenamento (KHAN *et al.*, 2023a).

De acordo Yang *et al.* (2023a) a estratégia de potencial de mitigação tem a melhoria da poupança de energia, a otimização operacional e a recuperação de energia térmica como as três principais possibilidades para reduzir as emissões de gases de efeito estufa nas estações de tratamento de águas residuais da China. Observa-se que nos últimos 15 anos aumentou a intensidade da eletricidade, representando 52% das emissões totais dentro deste setor.

A implementação de tecnologias de conversão de energia pode eliminar os combustíveis externos nas estações de tratamento de águas residuais no Japão, reduzindo 118% das emissões de gases de efeito estufa num horizonte de 15 anos em cerca de 14 grandes cidades deste país, de 2015 a 2030, integrando a incineração com a produção de energia térmica a partir de resíduos e a digestão anaeróbia utilizando a recuperação de combustíveis sólidos (WANG; NAKAKUBO, 2022). Neste contexto, a avaliação dos pesquisadores se concentra na verificação da eficiência obtida utilizando catalisadores químicos produzidos à escala industrial em conjunto com o controle do processo e a obtenção de dados por sensores (DHOKE *et al.*, 2021).

Embora as tecnologias CCS sejam ainda apresentadas como um investimento elevado, cerca de 40% do recurso econômico do projeto completo, dentro das tipologias térmicas, este pode variar significativamente dependendo da escala e se será utilizado em centrais próximas e onde a tecnologia será adquirida (SINGH *et al.*, 2022). Assim, a investigação científica é necessária, para minimizar custos e perdas com a CAC, possibilitando a geração de novos

produtos comercializáveis como biopolímeros e bioquímicos resultantes do menor impacto ambiental que será proporcionado com bom equilíbrio ecológico (YAASHIKAA *et al.*, 2023).

Um dos grandes desafios para a descarbonização é convencer a população mundial a aceitar a mudança no estilo de vida atual e os preços da energia com as técnicas atuais de remoção de dióxido de carbono para produzir energia, principalmente nos países mais ricos com uso intensivo de recursos e descargas. No entanto, o aumento das exigências com políticas ambientais eficientes e consistentes, melhorando as tecnologias de descarbonização com incentivos, utilizando tanto quanto possível os resíduos gerados em diferentes processos, pode ser uma alternativa para alcançar uma melhor redução das emissões em todo o mundo (PAPADIS; TSATSARONIS, 2020).

A produção de hidrogênio derivado de resíduos orgânicos é uma via valiosa para o fornecimento de energia com menos emissões e proporcionando descarbonização do que os métodos convencionais a partir de combustíveis fósseis, uma vez que a utilização de 90% como matéria-prima é originária de recursos poluentes com uma procura estimada de 8,6 Mt em 2020 a nível global (BERTASINI *et al.*, 2023).

No processo completo da cadeia de comercialização de biomassa para energia, analisar essa oferta por ferramentas de aprendizado de máquina melhora a capacidade de atender aos objetivos de desenvolvimento sustentável reduzindo incertezas e colaborando no aumento da eficiência e sua relação com o ecossistema de sequestro de carbono, operado dentro de todas as fases de plantio, colheita e operação da planta de transformação por análise de regressão sobre a capacidade que pode ser alcançada para armazenar o carbono emitido, reduzindo riscos na implementação desde a fase inicial até a operação de longo prazo (HELAL *et al.*, 2023). Apesar de exigir elevados investimentos, poderão estar associados a maiores ganhos no tratamento prévio da biomassa através de refinarias de biomassa, de modo a que se consiga um menor consumo de água, uma melhor eficiência de energia produzida por tonelada e produtos de maior valor econômico e maiores potências elétricas produzidas. Ainda, a sua sustentabilidade energética será avaliada em função das possibilidades de maximização dos controles relativos a medidas de segurança, saúde e ambiente que podem ser obtidas a partir da refinaria desenvolvida (YIN *et al.*, 2023).

2.7.1 Técnicas de Descarbonização

O tempo de reação e a taxa de aquecimento são os principais parâmetros que dividem intrinsecamente o processo de pirólise em lento e rápido, modificando o rendimento e os produtos gerados quando se trata das duas rotas tecnológicas mais utilizadas. No entanto, a captura de dióxido de carbono em qualquer uma dessas duas rotas com a adição de diferentes catalisadores e a influência desses parâmetros que estão sendo pesquisados é desconhecida por ser recente, ampliada pela dificuldade de recuperação do composto químico aplicado como catalisador e seus mecanismos de ação que diferem de acordo com a alocação desse in-situ ou ex-situ, sendo que a partir desse segundo modo ele é recuperado mais facilmente, pois o catalisador não se mistura

dentro do reator principal de pirólise promovendo maior filtragem (JIANG *et al.*, 2021a).

A pirólise lenta, comparada com a pirólise rápida, resulta em maior retenção de elementos traço no biocarvão de lodo de esgoto e outras biomassas, como resíduos de árvores urbanas, o que promove melhores características e aumenta a capacidade de ser fertilizante o biocarvão para aumento de nutrientes em diferentes solos e também promover a descarbonização (NACHENIUS *et al.*, 2013).

Existem algumas rotas técnicas para a captura de carbono, mas as mais aplicadas em todo o mundo são divididas em dois processos: pré-combustão e pós-combustão. Ambos atingem 90% de eficiência, mas precisam de investimentos significativos e uma quantidade de energia com a capacidade de produzir NO_x, resultando em emissões indesejadas. A segunda opção é implementada com um processo de adaptação que a torna flexível, principalmente devido às possibilidades econômicas de entrada. A primeira opção pode ser combinada com bioenergia para criar emissões negativas (DAVOODI *et al.*, 2023).

A adição de tendências relativas à produção de hidrogênio a partir de vias de baixo carbono, como pirólise de biogás, separação por membrana, gaseificação de biomassa, reforma de biogás e eletrólise para atingir metas sustentáveis e combustíveis derivados de recursos fósseis são alternativas que poderiam reduzir as emissões na perspectiva moderna, em que os projetos atuais de eletrólise com captura e armazenamento de carbono aumentaram 7,2 vezes sua eficiência em comparação com projetos anteriores (PLESHIVTSEVA *et al.*, 2023).

Uma reação com duas matérias-primas inseridas no reator é chamada de copirólise e, se forem inseridos produtos orgânicos, haverá a formação de água, que posteriormente, após a reforma do vapor, produzirá hidrogênio livre como combustível gasoso, principalmente na pirólise lenta. Reduzindo a taxa de carbono e oxigênio, a biomassa depende do tempo de reação, que afeta as propriedades e os rendimentos dos produtos gerados no processo de pirólise. Além disso, o desempenho e a interferência na captura de carbono nas várias tecnologias que estão sendo pesquisadas são desconhecidos e recentemente aplicados em nível industrial e experimental (KETOV *et al.*, 2022).

As unidades geradoras de eletricidade de pequeno porte são mais propensas às rotas termoquímicas de pirólise e gaseificação, que permitem a compactação das plantas por meio de técnicas como a incineração, facilitando as instalações próximas ao local onde está a biomassa ou a matéria-prima. Ela será oxidada e produzida onde poderá ser reutilizado o calor gerado ou subprodutos como o biocarvão em diversas aplicações energéticas e produtos tecnológicos como adsorventes de gás, células de combustível, supercapacitores, carvão ativado e carbono sequestrado pelo solo (DAS; PEU, 2022).

Li *et al.* (2023) analisou as pegadas de carbono de três tecnologias térmicas que são a liquefação hidrotérmica (HTL), a pirólise e a incineração com o software OpenLCA e o banco de dados Ecoinvent, verificando que a primeira citada tem a menor emissão de gases de efeito estufa, 172,50 kg CO₂eq/tonelada de lodo de esgoto, enquanto os processos de pirólise e incineração apresentaram 242,02 e 322,23, respectivamente, indicando que o HTL tem essa

vantagem principalmente por causa de sua taxa de consumo de energia em relação à energia de entrada e recuperada.

Incorporar uma mistura de diferentes agregados como biocarvão do processo de pirólise de serragem e cinzas de fundo da incineração de resíduos domésticos municipais é avaliado para captura e sequestro de CO₂, melhorando as propriedades mecânicas na indústria da construção e contribuindo para a estrutura de poros atribuída à nucleação de partículas de biocarvão formando agregados artificiais inovadores de captura de carbono com taxa máxima de carbono capturada em torno de 26,27 kg por tonelada desse composto misto (LIU *et al.*, 2023b).

De acordo com Wang *et al.* (2023a), o biochar em diferentes aplicações mitiga $2,56 \times 10^9$ emissões de gases de efeito estufa por ano, contribui como agente de imobilização no solo com fertilizante e tem potencial para ser um catalisador verde de biorrefinaria. O sólido digerido derivado do chorume bovino da digestão anaeróbica pode produzir material para a captura direta de óxido de carbono quando inserido em um reator de pirólise, aumentando a concentração de gás poluente de acordo com o aumento da temperatura de 400°C para 800° C devido ao volume de poros e à área de superfície (QUAN *et al.*, 2023a).

A recuperação do catalisador no tratamento térmico, como gaseificação e pirólise, é uma etapa importante para a descarbonização e a economia circular; no entanto, os processos ainda são caros, complexos e não confiáveis, pois os fatores econômicos são desafiadores, incluindo questões ambientais para catalisadores regenerativos (SUDALAIMUTHU; SATHYAMURTHY, 2024). Os líquidos iônicos capturam carbono composto de sais inorgânicos e ânions de coordenação devido às grandes estruturas moleculares que têm menor capacidade de adsorção; no entanto, a alteração da composição facilita o aumento da interação com a introdução de grupos carboxila ou amina, aumentando as proporções adsorvidas além do aumento da pressão, o que contribui para melhorar ainda mais essa capacidade (LIU; LU; HU, 2024).

A estratégia mais utilizada para a captura de CO₂ é a absorção por solventes, dividida em métodos físicos, químicos ou físico-químicos.

As tecnologias de captura pós-combustão de usinas de energia adaptadas resultam em 3-15 vol% de dióxido de carbono concentrado derivado de acordo com diferentes tipos de adsorventes, recuperando 82% com adsorção de oscilação de temperatura até 100% de CO₂ de adsorção de oscilação de vácuo usando carvão ativado (KRISHNAN; NIGHOJKAR; KANDASUBRAMANIAN, 2023). As principais considerações sobre adsorventes e absorventes para a remoção de CO₂ são estabilidade, segurança, custo e durabilidade, pois a combinação de dois ou mais tipos diferentes pode melhorar ou diminuir a eficiência. A incorporação de soluções de nano compostos e assistidas por enzimas é pesquisada para potencializar a ação em recursos de base biológica das tecnologias de captura de carbono (PEU *et al.*, 2023).

Captura de carbono para reforma de metano a vapor do processo de pirólise, o CO₂ volátil tem desvantagens em relação ao carbono sólido, pois não deve ser queimado, armazenado ou usado em um processo refinado para produzir outros compostos químicos para melhoria da economia circular e descarbonização, como produzir a categoria de hidrogênio azul (DERMÜHL;

RIEDEL, 2023).

A pesquisa de tecnologia de secagem de lodo é vital para a descarbonização, pois reduz o consumo de energia e as emissões de carbono. Esse processo pode ser responsável pela redução de 74,16% de carbono da incineração de lodo na China, de acordo com Chu *et al.* (2023), com tecnologia para utilizar o calor residual para reduzir as emissões de carbono, incluindo na desidratação e integrando sensores nesta parametrização e monitoramento em tempo real.

Os desafios para a remoção de CO₂ em temperaturas mais baixas com adsorventes ainda estão sendo investigados. Materiais como o lítio têm uma boa resposta devido à cinética rápida para capturar dióxido de carbono em temperaturas até mesmo de 823 K, mas precisam de melhor desempenho em baixas temperaturas, apesar de os adsorventes à base de CaO e MgO serem mais viáveis na produção de hidrogênio em comparação com outros, inclusive em temperaturas mais altas usando a quimissorção (ANIRUDDHA *et al.*, 2023).

Os materiais à base de carbono têm regeneração e custo-benefício desejáveis a partir de nanotubos, compósitos e aerogéis pesquisados na literatura científica sobre porosidade, química de superfície e arquitetura física, mas ainda exigem produtos químicos de alto custo para obter propriedades funcionais na captura de CO₂, aumentando a busca por aplicações microporosas e em larga escala com biomassa barata e abundante, como lodo de esgoto e microalgas, integrando-se a aplicativos de IA para atualizar modelos de laboratório (ZAKER *et al.*, 2023).

De acordo com Quan *et al.* (2023b), uma solução total de materiais de carbono baseados em biomassa para a captura de CO₂, incluindo biocarvão com adições de outros compostos químicos que promoveriam a adsorção de emissões de gases de efeito estufa e o efeito catalítico, é um tópico de pesquisa futura necessário, e uma solução sugerida de regeneração poderia ser a aplicação de materiais residuais para produtos como supercapacitores e baterias.

Outros resíduos típicos com uma enorme produção, utilizados atualmente no mercado de energia, podem ser soluções para compostos químicos que aceleram a rota da descarbonização. O bagaço da cana-de-açúcar é um subproduto que pode ser o grande responsável pela produção mundial de metanol por pirólise para a indústria química com coprodução de carbono negativo, integrando ativação física e loop químico com cenários que podem apresentar, nos cenários avaliados, um payback de até 7 anos, de acordo com Su *et al.* (2023), que avaliou três cenários e previu a viabilidade melhorada ao diminuir os custos do hidrogênio verde no futuro.

O gás natural renovável produzido por diferentes biomassas, como frações orgânicas de resíduos sólidos municipais e palha de milho com processo de gaseificação, pode ser competitivo com os preços do gás natural em 2024, estimados em 1,4 dólar americano/Joule (US\$/J), de acordo com Akbari e Kumar (2024), se for considerado o crédito de carbono mínimo de 90US\$/tonelada de dióxido de carbono e incluído o custo evitado de aterramento, contribuindo com as políticas de descarbonização.

A fonte de energia para a remoção de dióxido de carbono precisa ser de baixo carbono ou livre de carbono para gerar energia para o processo. Uma dessas soluções é a integração de duas tecnologias, a captura direta de ar integrada à bioenergia com captura e armazenamento

de carbono, fornecendo os requisitos de energia térmica e elétrica, principalmente usando a recuperação de calor durante o resfriamento do gás de síntese nos processos de gaseificação e pirólise (OKONKWO *et al.*, 2023).

2.7.2 Estado da arte da descarbonização em tratamentos térmicos de lodo para geração de energia elétrica considerando sensores e a aplicação de inteligência artificial

A remoção de poluentes da oxidação do carbono que pode ocorrer nos processos de geração de eletricidade, também chamada de descarbonização, por meio da aplicação de tecnologias como a captura e o armazenamento de carbono (CCS), possui diferentes vertentes de desenvolvimento tecnológico e científico sendo pesquisadas no nível da avaliação de configurações construtivas e do controle das variáveis físico-químicas dos reatores em processos térmicos como pirólise/gaseificação com simulações. No processo de descarbonização, o dióxido de carbono (CO₂) é convertido em monóxido de carbono (CO), um gás de combustão inflamável, para produzir outro insumo econômico com a reforma térmica e o vapor, que precisa ser aprimorada em usinas de grande escala. Ainda não se sabe se o teor de hidrogênio (H₂) diminui significativamente nessa operação de gaseificação/pirólise; entretanto, esse balanço se altera a partir da composição molar (%) do CO após ser capturado e reciclado. (CHAI; PACKHAM; WANG, 2022).

Atingir uma transição energética realista depende do estabelecimento de um caminho em que combustíveis de alta densidade energética sejam importantes para os padrões econômicos da civilização global, visto que a mudança climática é uma prioridade (CLOETE *et al.*, 2023). A maioria dos estudos se concentra separadamente nos impactos ambientais ou no desempenho energético dentro das usinas de energia. No entanto, propor um indicador que agregue ambos, desde o potencial de aquecimento global até a perda de eficiência exérgica unitária, avaliando os impactos do ciclo de vida de combinações de tecnologias de CCS em diferentes capacidades, é crucial para estabelecer a relação de compromisso de cada oportunidade ideal, diminuindo a emissão relacionada à energia dos sistemas de captura pós-combustão (XIE *et al.*, 2023). As soluções de otimização são uma forma de aprimorar os sistemas de energia nesse aspecto (Gomes e Souza *et al.*, 2022; LARROYD *et al.*, 2022; COLONETTI *et al.*, 2023).

Os desafios à adoção de sistemas de CCS (Captura e Armazenamento de Carbono) estão principalmente relacionados ao armazenamento/distribuição de compostos químicos gerados com dióxido de carbono, transformação de carbono e vapor de calor de uma turbina, o que afeta o retorno econômico ao longo do tempo e os esquemas de retrofit, aumentando o preço da eletricidade. Isso pode ser diferente na produção de metanol, cujo custo é quase zero em alguns tipos de usinas termelétricas (LIU *et al.*, 2023a).

A abordagem não só atende à necessidade urgente de reduzir as emissões de carbono, como também destaca o potencial de transformar um fluxo de resíduos em um recurso valioso. Ao aproveitar a energia latente no lodo por meio de tratamentos térmicos avançados, contribuímos para a diversificação das fontes de energia e reduzimos a dependência da geração de energia tradicional baseada em combustíveis fósseis. Essa modificação apoia uma infraestrutura

energética mais resiliente e sustentável e está em consonância com os esforços para mitigar as mudanças climáticas (MUNIZ *et al.*, 2023).

A busca pela descarbonização em tratamentos térmicos de lodo para geração de energia elétrica surge como uma solução atraente com implicações ambientais, econômicas e sociais significativas. O lodo de esgoto apresenta alto custo de tratamento e disposição final, com um ciclo de vida muito poluente em termos de emissões de metano e dióxido de carbono. As tecnologias térmicas atuam como um divisor nesse processo, transformando o lodo de esgoto em insumos valiosos para a cadeia de saneamento básico e produção de energia, e podem ser convertidos em biochar, óleo combustível, calor, eletricidade e hidrogênio, entre outros produtos, conforme abordado nesta pesquisa apresentado na figura 5:

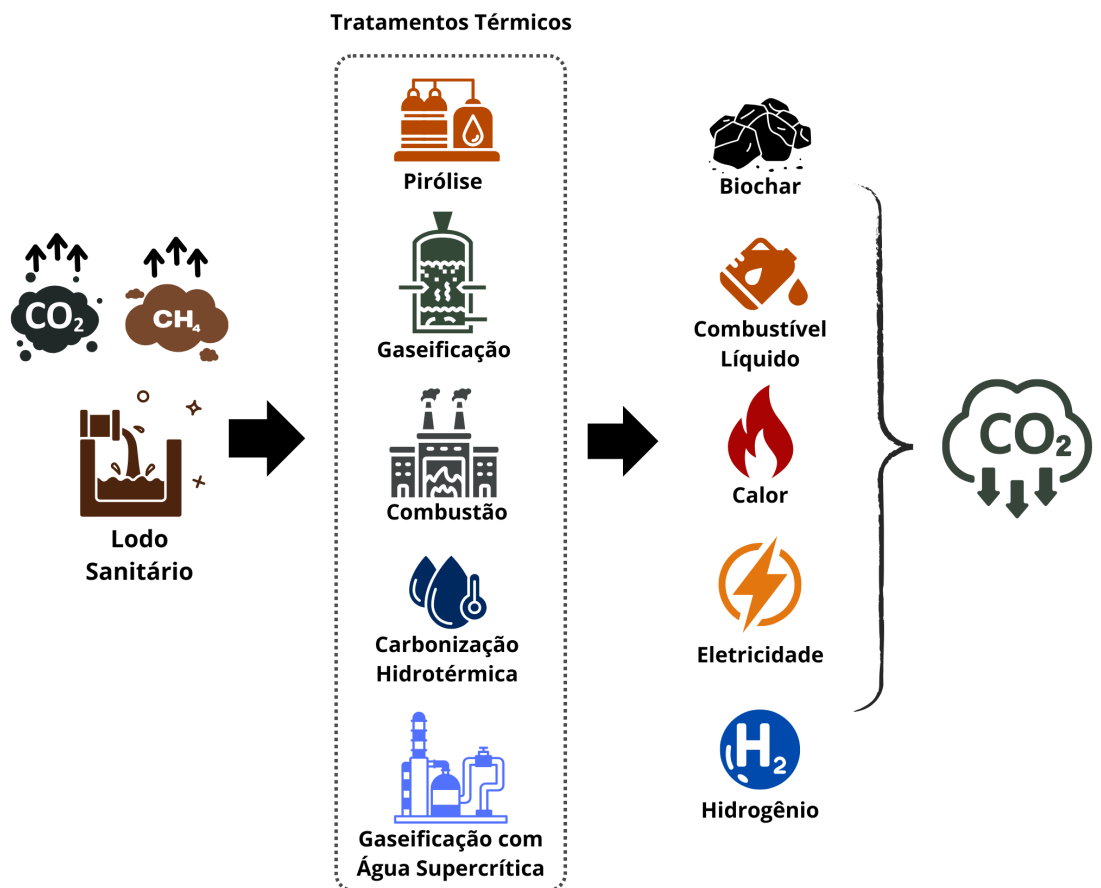


Figura 5 – Tecnologias para o tratamento térmico de lodo de esgoto e seus benefícios.

Fonte: Adaptado de (MUNIZ *et al.*, 2025)

A bioenergia representa uma importante fonte renovável para diversos países, e a integração desses recursos, com o aumento da captura de dióxido de carbono, pode trazer benefícios ambientais e elevar o preço mínimo de venda do combustível em interações comerciais, incluindo o resfriamento por compostos químicos disponíveis apenas para combustíveis fósseis, reduzindo essa dependência (MICHAGA *et al.*, 2022). A bioenergia representa uma importante fonte renovável para diversos países, e a integração desses recursos, com o aumento da captura de dióxido

de carbono, pode trazer benefícios ambientais e elevar o preço mínimo de venda do combustível em interações comerciais, incluindo o resfriamento por compostos químicos disponíveis apenas para combustíveis fósseis, reduzindo essa dependência (NANDHINI *et al.*, 2023).

Chu *et al.* (CHU *et al.*, 2024) realizaram pesquisas sobre a viabilidade da neutralidade de carbono na indústria de tratamento de lodo e seus resultados mostraram que a previsão realista é de 30.291,65 kt COe em 2030 e que a possibilidade de otimização depende da melhoria do processo de secagem para atingir 5.816,19 kt COe nessa mesma projeção anual. Os campos de tratamento de águas residuais são responsáveis por até 7% e 10% do metano e óxido de nitrogênio provenientes de emissões humanas, sendo 60% derivados dos processos e 30% referentes a uma contribuição indireta relacionada à energia. A descarbonização pode ser alcançada por meio da otimização do uso de produtos químicos e do transporte (MAKTABIFARD *et al.*, 2023).

Os principais obstáculos ao transporte limpo são o planejamento financeiro para a demanda a longo prazo, a aceitação social e a disposição de pagar preços mais altos por combustíveis alternativos até que se alcance uma melhoria na produção, por meio de pesquisa e desenvolvimento, estabilidade regulatória e investimento em tecnologia de captura direta de ar em instalações de produção e armazenamento em larga escala (KHAN *et al.*, 2023a).

De acordo com Yang *et al.* (YANG *et al.*, 2023a) a estratégia de mitigação potencial tem como três principais possibilidades a melhoria da economia de energia, a otimização operacional e a recuperação de energia térmica para reduzir as emissões de gases de efeito estufa em estações de tratamento de águas residuais na China. Nos últimos 15 anos, a intensidade do consumo de eletricidade aumentou, representando 52% do total de emissões nesse setor. Promover soluções que considerem esses fatores melhora o desempenho da remoção de poluentes, além de reduzir os custos.

Neste contexto, a avaliação por pesquisadores na verificação da eficiência obtida com o uso de catalisadores químicos produzidos em escala industrial, em conjunto com o controle de processos e a obtenção de dados por sensores (DHOKE *et al.*, 2021).

Há necessidade de selecionar o processo de captura de carbono, que apresenta uma ampla gama de opções em um contexto comercial e ainda está em desenvolvimento, determinado pela porcentagem de CO encontrada no gás de oxidação utilizado ou gerado dentro ou fora do reator térmico que produzirá gases combustíveis posteriormente convertidos em eletricidade (SUN *et al.*, 2022).

Na tabela 1, são apresentados exemplos de diferentes métodos de tratamento de lodo de CO.

Tabela 1 – Emissões de CO₂ de diferentes métodos de tratamento térmico de lodo.

Método de tratamento	Exemplos de CO₂ Emissões (kg/ton)	Referência
Digestão anaeróbia	120	(LI; ZHAO, 2020)
Compostagem	250	(SMITH; KUMAR, 2021)
Incineração	950	(ZHANG; CHEN, 2022)
Aterro	600	(WANG; LEE, 2019)

Embora as tecnologias de CCS ainda sejam apresentadas como um investimento elevado, em torno de 40% dos recursos econômicos de todo o projeto, dentro das tipologias térmicas mencionadas anteriormente, esse percentual pode variar significativamente dependendo da escala, da proximidade entre as usinas e da origem da tecnologia (SINGH *et al.*, 2022). Assim, a pesquisa científica é necessária para minimizar custos e perdas com CCS, possibilitando a geração de novos produtos comercializáveis, como biopolímeros e produtos bioquímicos, resultantes do menor impacto ambiental e que proporcionarão um bom equilíbrio ecológico (YAASHIKAA *et al.*, 2023).

Um dos grandes desafios para a descarbonização é convencer a população mundial a aceitar a mudança no estilo de vida atual e nos preços da energia, com as técnicas de remoção de CO₂ para geração de energia, principalmente nos países mais ricos, com uso intensivo de recursos e grande geração de emissões. No entanto, o aumento da demanda por políticas ambientais eficientes e consistentes, o aprimoramento das tecnologias de descarbonização e o incentivo ao aproveitamento, sempre que possível e rentável, dos resíduos gerados em diferentes processos podem ser uma alternativa para alcançar uma redução de emissões mais significativa em todo o mundo (PAPADIS; TSATSARONIS, 2020).

Uma arquitetura de alto nível para integrar unidades térmicas em estações de tratamento de águas residuais (ETAR) existentes envolve o pré-tratamento do lodo por meio de desidratação e secagem, seguido de conversão via pirólise, gaseificação ou métodos hidrotérmicos. Esses processos geram energia e subprodutos valiosos, como o biochar, que pode ser usado para sequestro de carbono. A integração com sistemas de captura de carbono e controles em tempo real baseados em IA aumenta a eficiência e reduz as emissões. Essa configuração permite que as ETARs recuperem energia, reduzam os gases de efeito estufa e apoiem uma economia circular (BORA; RICHARDSON; YOU, 2020).

Em todo o processo da cadeia de comercialização de biomassa para energia, a análise dessa oferta por meio de ferramentas de aprendizado de máquina aprimora a capacidade de atingir os objetivos de desenvolvimento sustentável, reduzindo incertezas e contribuindo para o aumento da eficiência e sua relação com o ecossistema de sequestro de carbono operado em todas as fases de plantio, colheita e operação da usina de transformação, por meio de análise de regressão sobre a capacidade que pode ser alcançada para armazenar o carbono emitido, reduzindo os riscos na implementação desde o estágio inicial até a operação em longo prazo (HELAL *et al.*, 2023).

Vale ressaltar que algumas tecnologias, como a pirólise e a gaseificação, oferecem uma gama mais ampla de aplicações e produtos em comparação com outras. A escolha da tecnologia mais adequada dependerá das características específicas do lodo, das necessidades locais e dos custos associados a cada processo. Além disso, a integração de diferentes tecnologias, como a combinação da gaseificação com a captura e armazenamento de carbono (CCS) ou o uso de biochar proveniente da pirólise para aprimorar a captura de carbono, pode levar a sistemas mais eficientes e sustentáveis (SHAW; MUKHERJEE, 2022).

No que diz respeito às duas vias tecnológicas mais populares, o rendimento e os produtos obtidos são alterados pelos parâmetros primários que inerentemente separam o processo de pirólise em lento e rápido: tempo de reação e taxa de aquecimento. Contudo, por ser um processo novo e complexo devido aos mecanismos e dificuldades de recuperação da molécula química utilizada como catalisador, ainda não se sabe ao certo como o CO₂ é capturado em qualquer uma dessas duas vias com a adição de diferentes catalisadores e qual o impacto desses parâmetros em investigação. A ação do catalisador varia conforme o processo seja *in situ* ou *ex situ*, sendo mais fácil a sua recuperação no segundo modo, pois o catalisador não se mistura dentro do reator de pirólise primário, permitindo uma filtração mais eficiente (JIANG *et al.*, 2021a).

Existem algumas rotas técnicas para a captura de carbono, mas as mais aplicadas mundialmente dividem-se em dois processos: pré-combustão e pós-combustão. Ambos atingem 90% de eficiência, mas exigem investimentos significativos e um grande consumo de energia, com potencial para produzir NO_x, resultando em emissões indesejáveis. A segunda opção é implementada por meio de um processo de adaptação, o que a torna flexível principalmente devido às possibilidades econômicas de utilização dos insumos. A primeira opção pode ser combinada com bioenergia para gerar emissões negativas. (DAVOODI *et al.*, 2023).

Pequenas centrais elétricas tendem a utilizar os processos termoquímicos de gaseificação e pirólise, que permitem a compactação da planta por meio de métodos como incineração e instalações próximas à biomassa ou matéria-prima. Esta sofrerá oxidação e será produzida de forma a permitir a reutilização do calor gerado ou de subprodutos como o biochar em diversas aplicações energéticas e bens tecnológicos, incluindo carbono sequestrado pelo solo, adsorventes de gases, células a combustível, supercapacitores e carvão ativado (DAS; PEU, 2022).

De acordo com Wang *et al.* (WANG *et al.*, 2023a) o biocarvão, em diferentes aplicações, mitiga 2,56 x 10 emissões de gases de efeito estufa por ano, contribui como agente imobilizador no solo com fertilizantes e tem potencial para ser um catalisador verde em biorrefinarias. O digestato sólido derivado de chorume bovino proveniente da digestão anaeróbica pode produzir material para captura direta de dióxido de carbono quando inserido em um reator de pirólise, aumentando a concentração do gás poluente de acordo com o aumento da temperatura de 400 °C para 800 °C devido ao volume de poros e à área superficial. (QUAN *et al.*, 2023a).

A recuperação de catalisadores em tratamentos térmicos como gaseificação e pirólise é uma etapa importante para a descarbonização e a economia circular; no entanto, os processos ainda são caros, complexos e pouco confiáveis, visto que fatores de custo-benefício, incluindo questões ambientais, representam desafios para catalisadores regenerativos (SUDALAIMUTHU; SATHYAMURTHY, 2024).

A estratégia mais utilizada para a captura de CO₂ é a absorção por solventes, dividida em métodos físicos, químicos ou físico-químicos. A solução física utiliza carbonato de propileno ou polietilenoglicol em diferentes condições, incluindo alta pressão de operação, sendo esses os principais solventes utilizados atualmente. No entanto, isso não impede a atuação dos métodos químicos em baixas pressões, apesar do alto consumo de energia devido às perdas por evapo-

ração e à degradação oxidativa, que precisam ser minimizadas com melhor absorção de calor, apresentando eficiência inferior à dos métodos físicos. Por conta desse problema, a integração de ambas as soluções é importante para combinar as vantagens de cada uma. Outras possibilidades tecnológicas, como a combustão em ciclo eletroquímico e o uso de microalgas, apresentaram avanços importantes, mas ainda não são utilizadas em larga escala para aplicações comerciais (LIU; LU; WANG, 2023).

As tecnologias de captura pós-combustão em usinas de energia modernizadas resultam em uma recuperação de 3 a 15% em volume de CO concentrado, dependendo do tipo de adsorvente utilizado. A recuperação varia de 82% com adsorção por variação de temperatura (TSA) até 100% com adsorção por variação de vácuo (VSA) utilizando carvão ativado. (KRISHNAN; NIGHOJKAR; KANDASUBRAMANIAN, 2023). As principais considerações relativas a adsorventes e absorventes para remoção de CO são estabilidade, segurança, custo e durabilidade, visto que a combinação de dois ou mais tipos diferentes pode melhorar ou diminuir a eficiência (PEU *et al.*, 2023).

A captura de carbono no processo de reforma a vapor do metano por pirólise, onde o CO volátil apresenta desvantagens em relação ao carbono sólido, pois não deve ser queimado, sendo armazenado ou utilizado em processos de refino para a produção de outros compostos químicos. Isso contribui para a economia circular e a descarbonização, como a produção de hidrogênio azul (DERMÜHL; RIEDEL, 2023).

A redução da demanda por petróleo, incluindo a inserção de biocombustíveis como o diesel verde e o etanol, deve ser alcançada até 2050, com uma participação significativa no setor de transporte de cargas. Isso ocorre porque a produção de nafta pode ser realocada para o coprocessamento de biomassa, evitando o aumento das emissões com a instalação de unidades de reforma a vapor de metano. É fundamental avaliar a individualidade de cada refinaria, alinhando-a aos objetivos de descarbonização, verificando a viabilidade comercial dos ativos, integrando-os ao mercado de carbono, exportando esses custos e reduzindo os riscos de emissões negativas, negociando emissões negativas de acordo com o perfil do produto final e os investimentos necessários (BERGMAN-FONTE *et al.*, 2023).

A pesquisa sobre a tecnologia de secagem de lodo é vital para a descarbonização, pois reduz o consumo de energia e as emissões de carbono. Segundo Chu, esse processo pode ser responsável por uma redução de 74,16%, nas emissões. *et al.* (CHU *et al.*, 2024) na China, a redução de carbono proveniente da incineração de lodo, com tecnologia para utilização do calor residual na redução das emissões de carbono, incluindo a desidratação, exige a previsão da importância de outra tecnologia térmica que integre sensores para parametrização e monitoramento em tempo real.

Materiais à base de carbono apresentam regeneração desejável e custo-benefício, como nanotubos, compósitos e aerogéis, conforme pesquisado na literatura científica sobre porosidade, química de superfície e arquitetura física. No entanto, ainda requerem produtos químicos de alto custo para obter propriedades funcionais na captura de CO, o que impulsiona a busca por

aplicações microporosas e em larga escala com biomassa abundante e de baixo custo, como lodo de esgoto e microalgas, integrando-as com aplicações de inteligência artificial para aprimorar modelos de laboratório (ZAKER *et al.*, 2023).

De acordo com Klaar *et al.* (KLAAR *et al.*, 2023a), combinar métodos pode ser uma solução promissora para aprimorar as abordagens de aprendizado profundo preditivo.

Outros resíduos típicos com grande produção, utilizados atualmente no mercado de energia, podem ser soluções para compostos químicos que aceleram a rota de descarbonização. O bagaço de cana-de-açúcar é um subproduto que pode ser amplamente utilizado na produção mundial de metanol por pirólise para a indústria química, com coprodução de carbono negativo, integrando ativação física e ciclo químico, com cenários que podem apresentar retorno do investimento em até 7 anos. Su *et al.* (SU *et al.*, 2023) avaliaram três cenários e previram que a viabilidade melhoraria com a redução dos custos do hidrogênio verde no futuro.

A fonte de energia para a remoção de CO precisa ser de baixo carbono ou livre de carbono para gerar energia para o processo. Uma das soluções é integrar duas tecnologias: captura direta de ar combinada com bioenergia e captura e armazenamento de carbono, suprimindo as necessidades de energia térmica e elétrica principalmente por meio da recuperação de calor durante o resfriamento do gás de síntese nos processos de gaseificação e pirólise. (OKONKWO *et al.*, 2023).

2.7.3 Tratamento térmico de lodo

O lodo de esgoto municipal, por ser um material com alto teor de umidade, torna seu aproveitamento energético dispendioso, sendo geralmente realizada uma análise de pré-tratamento para otimizar seu potencial energético, considerando os custos associados e os possíveis ganhos de energia em uma rota térmica. Visando à parametrização da desidratação otimizada do lodo, principalmente em relação aos fatores de temperatura, granulometria e volume, que podem ser realizados experimentalmente ou computacionalmente, a aplicação de mecanismos computacionais é considerada de grande interesse, visto que os custos dos processos experimentais geralmente apresentam custos comparativamente mais elevados. Isso possibilita a verificação prévia dos fatores intervenientes na cinética e termodinâmica do reator, por meio do estabelecimento de diferentes taxas de aquecimento através de simulações numéricas e algoritmos de aprendizado de máquina. Esses algoritmos podem prever a porcentagem de produtos gerados, simular análises laboratoriais como a análise termo gravimétrica, taxas de distribuição química de elementos como o hidrogênio e antecipar rotas de otimização (ADIBIMANESH *et al.*, 2023).

A aplicação do processo de carbonização com lodo de esgoto municipal recomenda a desidratação de pelo menos 60% antes da entrada no sistema, para evitar a necessidade de energia externa e estabelecer uma temperatura constante de até 400 °C na pirólise. Parte do óleo e gás produzidos, com um coeficiente de ar entre 2,6 e 2,8, é utilizada na câmara de incineração para fornecer calor, reduzir a umidade e garantir o auto equilíbrio energético (ZHOU *et al.*, 2023).

A co-incineração em usinas termelétricas a carvão e a pirólise de lodo municipal são as

Tabela 2 – Parâmetros-chave e aplicações de IA/software para técnicas de descarbonização.

Técnica	Parâmetros do processo	Características da matéria-prima	Condições operacionais	AI / Software
Pirólise	Desidratar para $\geq 60\%$ sólidos. Aquecimento para $400\text{ }^\circ\text{C}$ (constant). Coeficiente de ar 2.6–2.8 na câmara de incineração.	Lodo municipal, pré-seco $\geq 60\%$ sólidos.	Utilizar parte do petróleo/gás produzido para autoaquecimento.	Aprendizado de máquina (ML) para prever rendimentos de produtos, simular termogravimetria e otimizar rotas.
Gaseificação	—	Lodo de esgoto seco com secagem por instalação solar.	Leito de CaO ; agente de vapor. gás de síntese: H ₂ 70–73 vol%; CO 2–3 vol%; CO ₂ 8 vol%.	Simulação Aspen Plus (balanços de massa de gás de síntese).
Co-combustão	—	Lodo misturado em caldeiras a carvão.	Co-incineração em usinas de carvão modernizadas. Aquecedores baixo-NO _x nos queimadores; captura de amina pós-combustão.	—
Carbonização hidrotérmica	—	Lodo desidratado (15 % umidade). Catalisador ácido (HCl) para diminuir a relação Ni/Cr; ↑Fósforo em hidrocarvão.	Umidade média (KOSTOWSKI <i>et al.</i> , 2024).	—

duas melhores tecnologias na China, conforme declarado por Huang *et al* (HUANG *et al.*, 2023) que compararam a digestão anaeróbica e a mono incineração, no que diz respeito ao desempenho ambiental e econômico, resultante principalmente do uso de produtos químicos e do consumo de eletricidade. O teor de matéria orgânica e a taxa de recepção de lodo são os dois fatores que geralmente aumentam a diferença de competitividade entre os quatro sistemas comparados.

A energia térmica residual durante o processo de carbonização de talos de milho juntamente com lodo de esgoto, de acordo com Zhou *et al.* (ZHOU *et al.*, 2023a), promove a redução das emissões de gases de efeito estufa em 126,74 kg/ton, obtendo-se uma redução de custos de US\$ 23,12 em comparação com a incineração de lodo, gerando 541 kWh de eletricidade e permitindo a secagem completa de 1,2 toneladas de lodo para cada 1,5 toneladas de palha de milho.

As plantas de tratamento térmico de lodo em escala piloto e de demonstração variam amplamente em capacidade e desempenho, refletindo tanto a maturidade tecnológica quanto a diversidade de matérias-primas(YANG *et al.*, 2019). Por exemplo, a gaseificação de lodo seco ao sol com CaO, aprimorada por sorção, produziu gás de síntese com 70–73% de H₂, 2–3% de CO e cerca de 8% de CO em volume. Outro sistema relatado alcançou uma produção térmica de 2,54 kW/kg e uma produção elétrica de 0,81 kW/kg utilizando sólidos secos, reduzindo as emissões de CO em 0,59 kg por kg de lodo em comparação com a combustão de gás natural. Os sistemas de pirólise normalmente requerem lodo com pelo menos 60% de sólidos, operam a 400 °C e podem gerar energia significativa a partir da reutilização dos gases e óleos da pirólise. Os rendimentos de hidrogênio de diversas tecnologias variam de 5,5 a 10 kg/ton de lodo.

A heterogeneidade do lodo, particularmente a variabilidade no teor de umidade, na composição orgânica e na presença de metais pesados, afeta o rendimento energético e a estabilidade do reator. A variabilidade sazonal agrava ainda mais esses problemas, alterando a consistência da matéria-prima e, muitas vezes, exigindo ajustes em tempo real. Incrustações e corrosão são problemas persistentes, especialmente em sistemas de alta temperatura, como a gaseificação supercrítica, onde os materiais devem suportar tanto o estresse térmico quanto condições quimicamente agressivas. Esses desafios ressaltam a necessidade de um monitoramento robusto do processo, materiais resistentes à corrosão e sistemas de controle adaptativos, frequentemente guiados por inteligência artificial, para garantir uma operação confiável e eficiente(MORGANO *et al.*, 2024).

O biocarvão derivado de lodo de esgoto apresenta diferentes potenciais, visto que a adsorção de micropoluentes apresenta uma taxa de remoção que varia de 49% a 99% em água potável e 92% em águas residuais, sendo, portanto, considerado um material adsorvente promissor para a remoção eficaz de poluentes orgânicos, patógenos e metais pesados. Além disso, contribui para a melhoria da qualidade do ar, com o objetivo de sequestrar carbono, atingindo uma capacidade de 48 mg/g a um máximo de 182 mg/g de CO com biochar derivado de lodo de esgoto modificado com KOH. É importante estabelecer uma padronização para garantir qualidade e eficácia consistentes para essa aplicação ambiental, e o governo pode auxiliar a produção

industrial com incentivos, regulamentações associadas a créditos fiscais e subsídios.(KHAN *et al.*, 2023b).

A economia circular dos produtos da pirólise, como o carvão vegetal, apresenta potencial como um bom fertilizante para o solo, atuando como sequestrador de carbono. Essa tecnologia térmica pode fechar o ciclo de materiais, permitindo a conversão de polímeros em seus monômeros constituintes, além da reutilização de petróleo e gás no ciclo produtivo das indústrias. Os principais desafios da pirólise são o alto consumo de energia. Em países desenvolvidos, embora existam instalações para implementar essa tecnologia em escala industrial, é necessário que a legislação reconheça os benefícios dos produtos e estabeleça um mercado sólido (ANDOOZ *et al.*, 2023).

Se o biocarvão derivado de lodo pudesse ser aplicado em solos contaminados de áreas pós-industriais degradadas na Europa, com áreas iguais ou superiores a 45 mil km², com 0,8 toneladas de carbono por hectare, o maior índice de sequestro de carbono no solo para esse material, seria possível capturar entre 23 e 84 milhões de toneladas métricas de CO provenientes da pirólise de lodo de esgoto até 2055(SAJDAK *et al.*, 2023).

Ao inserir plásticos em lodo de esgoto para produzir biocarvão no processo de pirólise, é possível melhorar a estrutura do carbono, principalmente com o polipropileno, beneficiando as propriedades da superfície e a estrutura dos poros. A mistura com cloreto de polivinila reduz os potenciais riscos ecológicos, pois inibe a liberação de sulfeto de hidrogênio, dióxido de enxofre e cloreto de metila, que são gases nocivos (SHEN *et al.*, 2023).

A pirólise de lodo de esgoto pode apresentar vantagens e desvantagens, pois a sazonalidade contribui para o alto teor de água e a grande concentração de carbono beneficia os microrganismos patogênicos, enquanto os elevados teores de nitrogênio e fósforo geram substâncias nocivas. O controle de parâmetros na automação é importante para estabelecer soluções mais integradas com tratamentos térmicos que superem as desvantagens dos controladores de ponto de ajuste (SLEZAK *et al.*, 2023).

O biocarvão derivado de lodo de esgoto é uma tecnologia promissora para a recuperação de fósforo e pode ser consideravelmente acelerado com o uso de CaCO₃. A adição de 10% desse composto químico tem o potencial de aumentar a conversão de fósforo inorgânico não apatítico em fósforo apatítico durante o processo de pirólise. Além disso, pode apresentar características que melhoram solos ácidos, economizando energia por reduzir a umidade quando inserido no processo de desidratação do lodo (ZHU *et al.*, 2023b).

A melhoria das propriedades físico-químicas do lodo de esgoto, integrando pré e pós-tratamentos, contribui para a seletividade na remoção de poluentes. A implementação em larga escala depende da capacidade de adsorção e da redução das limitações de aplicação, permitindo que os compostos reduzam as emissões de carbono, atuando como uma ferramenta no controle da poluição da água em estações de tratamento de efluentes (ZHAO *et al.*, 2023).

O controle da umidade do lodo não apenas contribuiu para a geração de hidrogênio, mas também reduziu as emissões de CO₂, conforme relatado por Lin *et al.*(LIN *et al.*, 2023) na

pirólise por micro-ondas, devido ao consumo de energia que diminuiu 35%, correspondendo a uma redução de 45,60% no aquecimento global com essa eficiência e mistura do resíduo da pirólise com biochar e catalisador.

Aditivos à base de cálcio em um sistema de co-pirólise de lodo de esgoto aumentaram o consumo de CO devido à massa e ao pH do biochar, melhorando a matéria orgânica dissolvida a partir do carbono e do conteúdo de componentes, aumentando a área superficial, já que o volume total de poros é importante para materiais de captura de carbono (CAI *et al.*, 2024a).

Além da área superficial e da porosidade, a basicidade e os grupos funcionais da superfície são parâmetros importantes para a captura de CO₂ por adsorção no interior do biocarvão (FANG *et al.*, 2023).

A neutralidade de carbono pode ser alcançada com energia e produtos de valor agregado derivados de lodo de esgoto, aprimorando o processo de tratamento por meio da aplicação de técnicas como oxidação avançada, reduzindo a produção de lodo ativado e promovendo tecnologias verdes de desidratação profunda. É fundamental verificar alternativas às cinzas em operações termoquímicas como incineração e gaseificação, incluindo aquelas relacionadas a concreto, cerâmica e pavimentos rodoviários, quando não houver geração de biochar ou bio-óleo por pirólise. A colaboração entre múltiplas tecnologias também é essencial (HU *et al.*, 2022).

O biocarvão proveniente da agricultura, como bagaço e serragem, misturado com agregado graúdo leve artificial aglomerado a frio, originário das cinzas de fundo da incineração de resíduos sólidos urbanos, apresenta boa capacidade de sequestro de carbono, conforme investigado por Liu *et al.* (LIU *et al.*, 2023) que comprovaram que a mistura desses compostos atinge de 30 a 33 kg de CO/ton, proporcionando uma solução economicamente eficiente.

A perda de energia causada pelos dispositivos de remoção de CO em torno de 20 a 30% é um problema para a produção de bioenergia. No entanto, a melhor opção atualmente é recuperar CO de alta pureza, atingindo 99%, para obter um mercado economicamente viável e promover uma economia circular. Alguns pesquisadores estão tentando alcançar esse objetivo utilizando nanomateriais biológicos como nanotubos de carbono, microalgas, lodo e resíduos de madeira (RAZA *et al.*, 2023).

Um modelo de sustentabilidade em uma refinaria que utiliza lodo de esgoto municipal como matéria-prima em um processo de pirólise pode pressupor a captura e o armazenamento de carbono por meio de gerenciamento e suporte à decisão com o auxílio de mecanismos avançados, como componentes meta-heurísticos. A aplicação de algoritmos de inteligência artificial, como redes neurais, para prever esses coeficientes, e o lodo com maior teor orgânico sugere a adoção de uma simbiose de tecnologias de pirólise com digestão anaeróbica, emitindo níveis mais baixos de CO e enxofre, reduzindo a necessidade de secagem, que pode consumir energia, gás natural ou outros combustíveis, visto que alguns modelos de reatores de pirólise podem ser danificados pelo excesso de água (CULABA *et al.*, 2022).

Muniz *et al.* (MUNIZ *et al.*, 2020) focaram na análise de ferramentas para medir a sustentabilidade energética, o que pode contribuir para a avaliação do impacto e da eficiência

das tecnologias térmicas utilizadas no tratamento de lodo. A utilização dessas ferramentas pode fornecer informações valiosas para a tomada de decisões relativas à implementação de tecnologias térmicas para o tratamento de lodo, permitindo a seleção de opções mais sustentáveis e eficientes.

O aumento da capacidade de produção de produtos em um reator de pirólise que utiliza lodo de esgoto como biomassa, a partir da previsão do rendimento de carvão e da taxa de fixação de nitrogênio em base seca, de modo a descartar o efeito da umidade e reduzir as incertezas do algoritmo de aprendizado de máquina, contribui para a determinação de parâmetros que podem ser correlacionados com a cinza produzida e que atualmente também podem ser avaliados quanto à degradação térmica dos constituintes lignina e celulose. Isso beneficia a previsibilidade de modelos bioquímicos, promovendo maior eficiência no processo térmico agregado, com a obtenção de estimativas de carbono fixado considerando cargas máximas e mínimas de biomassa inseridas no reator, proporcionando melhores condições de adsorção ao biocarvão produzido e possível melhor comercialização (LI *et al.*, 2023b).

O despacho otimizado é considerado essencial para a operação de usinas termelétricas, incluindo sistemas de captura de carbono, como na incineração de resíduos, ajustando a potência de saída à carga e ao horário das tarifas, e adotando mecanismos de comercialização de carbono do tipo escalonado, reduzindo os custos operacionais que podem ser avaliados para outros modelos de geração de lodo e outros (ZHENG *et al.*, 2023).

Um dos fatores preponderantes para a obtenção de uma previsão ótima e para o aumento da capacidade de otimização na produção de compostos com maior valor econômico agregado a partir de qualquer biomassa, incluindo lodo de esgoto municipal, é a qualidade dos dados. Quanto maior a homogeneidade das características dos equipamentos utilizados e da metodologia aplicada, melhor será esse equilíbrio qualitativo. Assim, o protocolo analítico torna-se indispensável para o modelo de futura refinaria de biomassa, a fim de lidar com as mudanças na composição da biomassa e manter a taxa de geração de produtos derivados da biomassa, minimizando a produção de resíduos. A incorporação na Indústria 5.0 exige um extenso banco de dados, fruto do avanço na implementação da Indústria 4.0 neste setor, a partir da caracterização prévia da biomassa, do método de pré-tratamento e do conhecimento aprofundado dos constituintes gerados nas rotas bioquímicas e termoquímicas do processo de pirólise (VELIDANDI *et al.*, 2023).

Entre as prioridades em uma planta de processamento está a redução constante do consumo de energia e, conseqüentemente, o aumento da produção e do lucro. Seguindo esse objetivo no tratamento térmico, busca-se maximizar o aproveitamento da transferência de calor e aplicar reagentes químicos que atuem como catalisadores, maximizando a ativação do carvão vegetal no biochar de pirólise lenta ou do bio-óleo em equipamentos de pirólise rápida. Aprimorando o balanço energético do processamento com outras biomassas, como microalgas, também aumenta o rendimento desse biocombustível, que pode ser avaliado por ferramentas computacionais e algoritmos de aprendizado de máquina, verificando o desempenho técnico e

ambiental dessa combinação de matérias-primas no reator antes do teste experimental (NASIR; MOHAMED; LI, 2023).

O biocarvão e o bio-óleo são os principais produtos derivados da pirólise lenta e rápida de lodo de esgoto, respectivamente. O rendimento do produto primário e o valor de mercado são os dois principais fatores responsáveis pela aplicação do pré-tratamento e pós-tratamento com carvão ativado. A secagem térmica é crucial para alcançar a viabilidade econômica, e o uso de menos ácido como reagente ativador impacta positivamente os aspectos financeiros e ambientais (HUANG; MOHAMED; LI, 2022). Além desses trabalhos, muitas outras aplicações foram destacadas para o desenvolvimento sustentável em diversos campos (FAKOYA; IMUEZERUA, 2020; BARSKA *et al.*, 2020; MARTINHO; MOURÃO, 2020).

Cada um dos métodos de tratamento térmico de lodo apresenta vantagens e desvantagens, conforme descrito na Tabela ?? uma comparação entre eles é apresentada. Na próxima seção, serão discutidos os principais fatores para a implementação da sustentabilidade nos processos de geração de energia térmica.

O tratamento térmico de lodo de esgoto, incluindo incineração, pirólise, gaseificação e processos hidrotérmicos, alcança a maior redução de sólidos (até 90%) e garante a destruição quase completa de patógenos, com opções para recuperação de energia, mas é um processo que exige alto investimento de capital e energia, além de gerar preocupações com emissões atmosféricas. Em contrapartida, estratégias biológicas e baseadas na terra, como a digestão anaeróbica, a compostagem e a aplicação no solo, apresentam custos operacionais e pegadas de carbono mais baixos, permitem a recuperação de nutrientes na forma de biogás ou corretivos de solo e requerem menos energia auxiliar, mas alcançam apenas uma redução volumétrica moderada (20–60%) e podem deixar patógenos ou contaminantes residuais se não forem gerenciadas com cuidado (ZHANG *et al.*, 2024c).

2.7.4 Aplicações de IA no tratamento de lodo

Shao et al. (SHAO *et al.*, 2023) desenvolveram um estudo comparativo abrangente de nove algoritmos de aprendizado de máquina para prever a produção de lodo em estações de tratamento de esgoto. Usando dados operacionais reais, incluindo volume de entrada, temperatura e qualidade do esgoto, descobriram que métodos de conjunto, como Extreme Gradient Boosting e Random Forest, alcançaram a melhor precisão (coeficiente de determinação de até 0,82), e a análise de sensibilidade destacou a vazão diária de entrada e a temperatura ambiente como fatores-chave na produção de lodo.

Em uma revisão apresentada por Sun et al. (SUN *et al.*, 2024) sobre aplicações de aprendizado de máquina (ML) na reciclagem termoquímica de lodo municipal, pesquisadores destacaram como modelos supervisionados, particularmente o gradient boosting e as máquinas de vetores de suporte (SVM), podem elucidar mecanismos de reação, otimizar parâmetros de processo e reduzir o consumo de energia em rotas de pirólise e gaseificação. Este trabalho fornece orientações práticas para a implementação de suporte à decisão baseado em ML em sistemas de

conversão de lodo em recursos.

2.8 FATORES IMPORTANTES PARA A IMPLEMENTAÇÃO DA CAPTURA DE CARBONO NO TRATAMENTO DE LODO

Os custos de manutenção e a viabilidade econômica são fatores vitais no desenvolvimento de um projeto de curto a longo prazo para a implementação da economia circular. Essa implementação pode ser viabilizada por meio de uma nova contextualização técnica do uso de subprodutos, através de novas rotas tecnológicas, juntamente com a compreensão das estruturas do modelo energético. Essas rotas podem contribuir com economias potenciais e significativas de despesas, que podem ser revertidas em lucros ou minimizadas ao longo do processo, como as cargas totais de fósforo, nitrogênio, demanda química de oxigênio e tarifas de energia relacionadas a sopradores e bombas em uma Estação de Tratamento de Esgoto, na recuperação desses nutrientes, como potássio, além de fósforo e nitrogênio, de metais pesados comercializáveis, como ferro e cobre, caso estejam presentes na composição do lodo (CECCONET; CAPODAGLIO, 2022).

Um exemplo do tratamento atual de esgoto é mostrado na Figura 8. No processo convencional, a água é desinfetada e enviada para um corpo hídrico receptor. O lodo de esgoto, resultante da separação e tratamento da água, segue para um equipamento chamado densificador, que promove a concentração de sólidos e reduz a quantidade de água em sua composição. O lodo espessado passa por um processo de secagem e desidratação, que apresenta altos custos de manutenção e alto consumo de energia elétrica. Em seguida, é enviado para disposição final em aterros sanitários, com altos custos logísticos. Uma vez depositado no aterro, a manutenção do lodo enterrado é dispendiosa, reduzindo a vida útil do aterro e gerando grandes emissões de gases de efeito estufa.

Na verificação do desempenho ambiental, é necessário verificar a aplicação que será dada ao produto gerado em um processo térmico, que pode ser nafta ou gás liquefeito de petróleo. Considerando a mesma aplicação e composição final derivadas de combustíveis fósseis, o ganho em sustentabilidade no resultado final é pequeno. Devido a esse problema, a ciência dos materiais produzidos é vital na reformulação de melhorias econômicas e ambientais, como o uso de biochar como material substituto em fornos de cimento, contribuindo para a redução do aquecimento global e da ecotoxicidade na água. (KELLER *et al.*, 2022).

Ao realizar uma análise de sensibilidade, os resultados tornam-se cruciais para a tomada de decisões. É indicado reavaliar e reanalisar os resultados para identificar diferentes tendências, principalmente na inserção de reagentes ou catalisadores no processo, que podem ampliar a gama de produtos disponíveis, e avaliar a taxa de ganho por concentração inserida desses compostos adicionados (TARPANI; AZAPAGIC, 2023).

Como forma de alcançar a neutralidade de carbono, ou seja, a capacidade de consumir efetivamente a mesma quantidade de carbono produzida em cada etapa do processo, um objetivo global é desenvolver biorrefinarias com controle autônomo por meio de modelos avançados, a

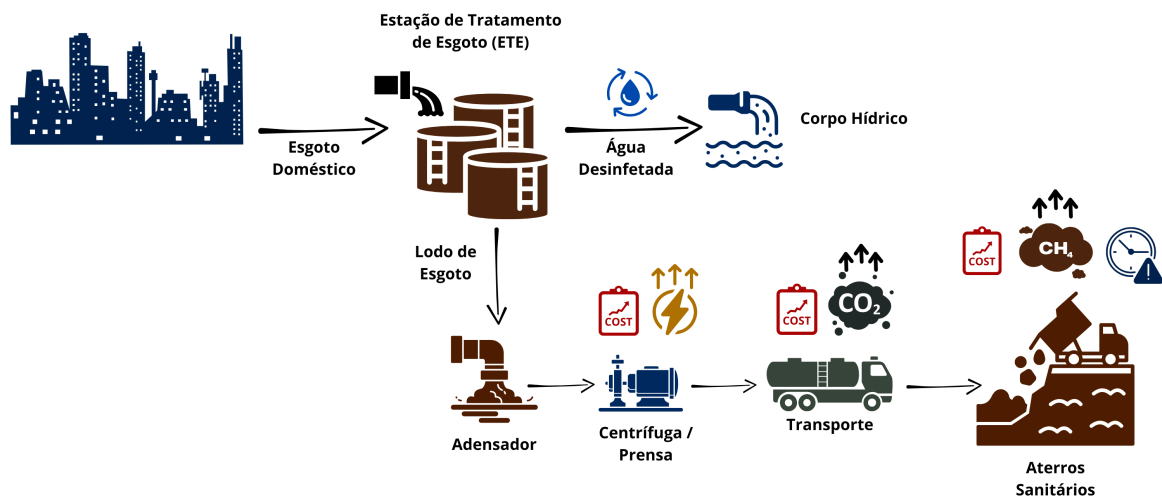


Figura 6 – Sistemas atuais de tratamento de esgoto.
Fonte: Adaptado de (MUNIZ *et al.*, 2025)

partir da parametrização de sistemas dinâmicos embarcados e com servidores de dados que armazenam, recebem e transmitem dados operacionais. Essas biorrefinarias também podem aplicar técnicas de minimização para gerar níveis de emissão aceitáveis e técnicas de maximização na qualidade e quantidade de combustível, fertilizantes e compostos químicos gerados.

A homogeneidade da matéria-prima, no caso do lodo de esgoto municipal, que apresenta particularidades mesmo sendo uma biomassa complexa devido à umidade e à composição química orgânica, contribui para a análise do consumo de energia em sistemas multidinâmicos que combinam o uso de energia térmica e elétrica. Além disso, permite a previsão de melhorias de desempenho, ou seja, maior eficiência energética, a partir de um extenso banco de dados de correlações entre os parâmetros de conformidade com as normas ambientais locais, dados climáticos e a energia elétrica consumida por dispositivos de aeração e na secagem do lodo de esgoto em estações de tratamento de esgoto (OLAFASAKIN *et al.*, 2021).

A conversão de calor e energia combinados a partir de lodo de esgoto pode ser otimizada com modelos computacionais (FRAIA *et al.*, 2022). O CO_2 capturado localmente apresenta uma enorme redução de emissividade incorporada na gaseificação em comparação com a global, atingindo $460 \text{ kgCO}_2/\text{MWh}$ e $296 \text{ kgCO}_2/\text{MWh}$, respectivamente. Combinando a produção de calor e energia, são gerados cerca de 5 MW ou mais de energia elétrica. As perdas de energia são maiores, principalmente devido ao fluxo de massa de extração de vapor para atender à demanda de reebulição e à energia necessária do compressor de combustível (BAK *et al.*, 2023).

Essa correlação entre a energia interna consumida na estação de tratamento de esgoto e o potencial de recuperação de energia pode ser realizada por meio de modelagem computacional, avaliando a remoção de poluentes e indicando se há melhorias na inserção e conjugação de novas

rotas tecnológicas(YANG *et al.*, 2023b).

Um dos principais desafios para a produção de hidrogênio a partir de lodo de esgoto ainda é o baixo rendimento e a baixa taxa de produção em processos biológicos e tecnologias térmicas. Embora haja possibilidades de aumentar o rendimento de ambas as técnicas com pesquisas sobre dosagem de nanopartículas, esse aspecto deve ser avaliado, incluindo a participação e a influência de cada material aplicado em uma rota catalítica para microrganismos ou participação química (KHAN *et al.*, 2024).

O bio-óleo produzido pela rota tecnológica da pirólise apresenta um enorme potencial para ser refinado em diversas aplicações industriais de materiais carbonáceos e ligantes, como o alcatrão bioasfáltico, composto líquido na formação do asfalto, e tem como principal vantagem a redução das emissões humanas em comparação com a transformação desse produto derivado de combustíveis fósseis, como o petróleo, bem como em sua conversão em biopolímeros gerados pela técnica de policondensação(QAMAR *et al.*, 2023).

Tecnologias como a pirólise e a gaseificação, embora exijam alto investimento inicial, apresentam retornos promissores a longo prazo quando avaliadas por meio de um cálculo abrangente do custo do ciclo de vida, que considera a redução da dependência de aterros sanitários, a recuperação de energia e a valorização de subprodutos como o biocarvão e o gás de síntese. (GONZÁLEZ; GARCÍA; PÉREZ, 2021). Os períodos de retorno do investimento para esses sistemas variam significativamente com base na escala da planta e na integração com tecnologias de captura de carbono, variando de 5 a 10 anos em configurações otimizadas, com benefícios adicionais de produtos como metanol e hidrogênio, que melhoram a viabilidade financeira. Cenários de crédito de carbono, especialmente sob estruturas de preços como € 90/ton CO na União Europeia (UE) ou esquemas comparáveis na China e no Brasil, aumentam ainda mais a rentabilidade, compensando as emissões e apoiando a viabilidade econômica de produtos com emissões negativas.

A UE adotou fortes incentivos à descarbonização por meio do Sistema de Comércio de Emissões e apoia a conversão de resíduos em energia através do Pacto Ecológico Europeu e da Diretiva de Energias Renováveis. O Brasil, por sua vez, incentiva a bioenergia por meio do RENOVA-BIO, que promove a redução da intensidade de carbono na produção de combustíveis. A China está integrando ativamente a conversão de lodo em energia em seus Planos Quinquenais, implementando inteligência artificial e automação robótica para aprimorar o monitoramento de emissões e o controle operacional, além de pilotar projetos de CCS em larga escala com mecanismos favoráveis de empréstimo e títulos verdes. Esses ecossistemas de políticas influenciam diretamente a adoção de tecnologias e a viabilidade econômica, ressaltando a necessidade de modelagem econômica localizada que incorpore externalidades ambientais e instrumentos de mercado para o carbono(LIEW *et al.*, 2021).

2.9 ALTERAÇÕES NECESSÁRIAS NA ESTAÇÃO DE TRATAMENTO DE ÁGUAS RESIDUAIS PARA REDUZIR O CO₂

Na estimativa do balanço de carbono, o consumo de produtos químicos pode se tornar um dos principais fatores preponderantes na emissão de gases de efeito estufa (GEE), especialmente quando polímeros como a poliacrilamida são aplicados nos processos de flotação e desidratação de lodo e glicose na desnitrificação. Essa carga poluente gerada é ainda maior quando se trata de processos industriais em comparação com o lodo de esgoto proveniente das cidades, tornando o consumo de energia mais intenso (CROLL *et al.*, 2023).

A remoção de nitrogênio e carbono colabora para a redução de GEE, enquanto os modos avançados de controle, comparados ao controle Proporcional-Integral-Derivativo (PID), permitem estabelecer parâmetros de eficiência operacional a partir do aprendizado reforçado na avaliação da correlação entre a obtenção de economia de energia em diferentes condições climáticas, com faixas distantes de ocorrência de multas ambientais associadas à obtenção de padrões ideais de consumo elétrico dos sopradores responsáveis pelo tratamento aeróbico e concentrado de íons por produtos químicos (OLMO *et al.*, 2023).

A avaliação por meio da avaliação do ciclo de vida contribui para verificar a relação entre a emissão de dióxido de carbono e outros impactos ambientais do gerenciamento de águas residuais, como ecotoxicidade de água doce, eutrofização, esgotamento da água, toxicidade humana e toxicidade de animais marinhos, conforme identificado para Zheng e Lam (2024), que verificaram que mais de 75% das categorias combinadas são influenciadas pelo aumento das emissões de gases de efeito estufa, mostrando que apenas avaliar os custos financeiros não é suficiente e deve ser medido o custo ambiental, pois é necessário adotar uma perspectiva mais ampla do sistema usando metanálise com diferentes fatores geográficos espaciais quando a estação de tratamento de águas residuais está localizada.

Portanto, é necessário implementar uma interface conjunta com linguagens de programação de aprendizado por reforço para sistemas SCADA (*Supervisory Control and Data Acquisition*) e software simulador de cinética térmica, química e elétrica. Entretanto, previamente, devem ser observados os custos de implementação e manutenção do armazenamento desse banco de dados vinculado ao modelo de aprendizado por reforço e os custos recorrentes de assinatura de serviços em nuvem, verificando se todos esses desembolsos serão inferiores aos gastos de energia que serão economizados com a aplicação desse mecanismo de inteligência artificial na estação de tratamento de esgoto (DEON *et al.*, 2022).

As direções futuras atribuídas ao armazenamento de energia e às relações de captura de CO₂ do biochar da pirólise de lodo de esgoto e a influência da força eletrostática de Van Der Waals, da área de superfície e dos grupos químicos funcionais dependem de adsorventes de baixa sensibilidade à umidade e alta estabilidade térmica produzidos com carvão ativado, que podem ser produzidos com lodo de esgoto derivado de processos térmicos e transformados com reagentes químicos em carbono de uma dimensão (nanotubos de carbono), duas dimensões

(grafeno) e três dimensões (carvão ativado), e sua aplicação citada anteriormente, como também a possibilidade de absorver contaminantes dentro da água. Devido a essas múltiplas finalidades e aplicações, é necessário avaliar quais desses produtos têm preços mais altos com propriedades de características na operação e custos mais baixos para produzir com tecnologias térmicas específicas (REZA *et al.*, 2023).

Uma análise comparativa das principais tecnologias de tratamento térmico para lodo de esgoto é apresentada na Tabela. 3. A tabela resume o nível de maturidade de cada tecnologia, as emissões típicas de gases de efeito estufa, a eficiência energética e o desempenho em termos de custos. Esses parâmetros são cruciais para avaliar a viabilidade ambiental e econômica das estratégias de descarbonização em sistemas de valorização energética de lodo. Ao avaliar essas tecnologias lado a lado, as partes interessadas podem tomar decisões informadas, alinhadas com as metas de sustentabilidade e mitigação das mudanças climáticas.

Tabela 3 – Comparação de tecnologias de tratamento térmico de lodo.

Tecnologia	Maturidade	Emissões	Eficiência energética	Custo (USD/ton)
Pirólise	Emergente	Médio para baixo, depende do desenho do reator (SHAHA-BUDDIN; KIBRIA; BHATTACHARYA, 2021)	Médio para Alto (bio óleo, carvão, saídas de gás)	Médio para Alto
Gaseificação	Emergente	Emissões mais baixas com vapor/CCA (JIANG <i>et al.</i> , 2021b)	Alto rendimento de hidrogênio (70–73%)	Médio
Co-combustão	Maduro	Altos níveis de GEE (gases de efeito estufa), a menos que seja utilizado tratamento pós-operatório. (VARINY <i>et al.</i> , 2021)	Moderado, utiliza co-combustão de combustíveis fósseis.	Baixo
Carbonização hidrotérmica	Emergente	Baixo, funciona com lodo úmido (ZHANG <i>et al.</i> , 2022)	Moderado (produção de hidrocarvão)	Alto
Gaseificação de água super-crítica	Em desenvolvimento	Muito baixo, poluentes atmosféricos mínimos (JIANG <i>et al.</i> , 2021b)	Produção de hidrogênio muito alta e eficiente.	Alto
Gaseificação por plasma	Em desenvolvimento	Muito baixo, com até 97% de captura de CO ₂ (ZHOU <i>et al.</i> , 2023b)	Alta (~50% eficiência)	Muito alto

Nesse contexto, existem tratamentos alternativos, como mostrado na Figura 7. O lodo denso não passa pelas etapas de secagem/desidratação, transporte e disposição final em aterros sanitários, processos dispendiosos em termos de operação e manutenção, além de emitir gases

de efeito estufa. Quando submetido a tratamento térmico, que pode ser realizado dentro da própria estação de tratamento de esgoto, o lodo é convertido em produtos de valor econômico e energético, promovendo a descarbonização e o sequestro de carbono, agregando novas receitas ao sistema convencional com a comercialização dos produtos resultantes, aumentando, assim, os ganhos sociais e os benefícios ambientais.

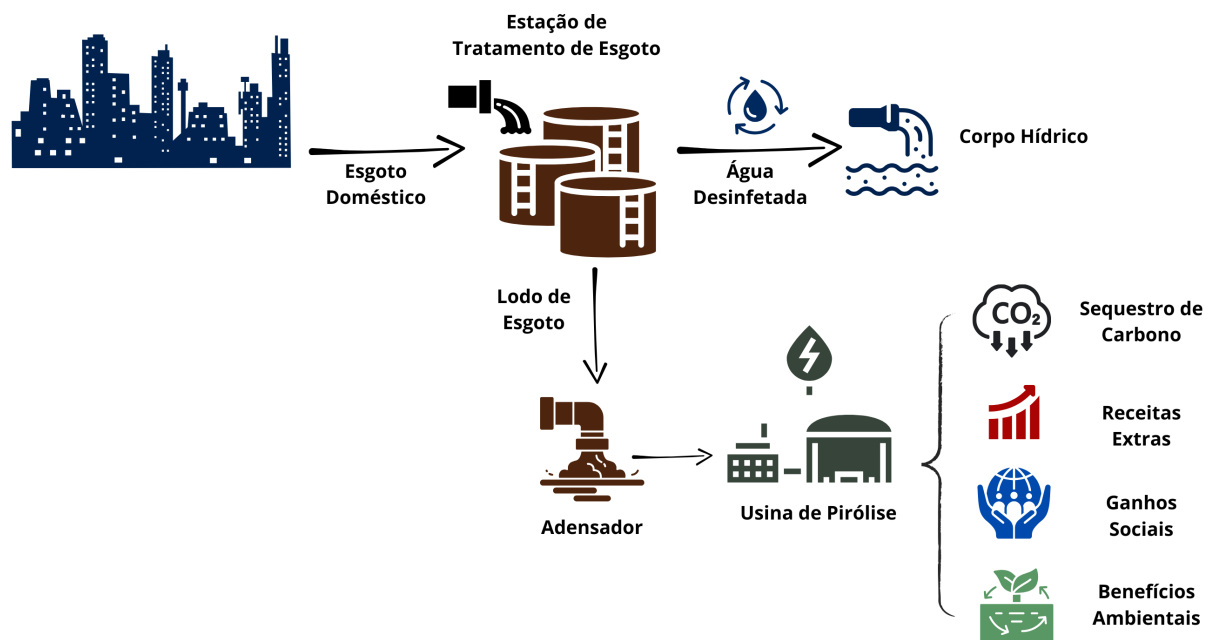


Figura 7 – Sistemas de tratamento alternativos.
Fonte: Adaptado de (MUNIZ *et al.*, 2025)

As emissões de carbono durante a operação da estação de tratamento de esgoto podem ser evitadas através da reciclagem desses resíduos, uma vez que os processos mecânicos são os principais contribuintes, em comparação com o consumo de eletricidade e produtos químicos, conforme relatado por (ZHANG *et al.*, 2024a) que verificaram o reaproveitamento de água como o principal potencial de redução das emissões de carbono para estações de tratamento de lodo de esgoto em operação, instaladas em processos anaeróbios-anóxicos-óxicos.

2.10 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A busca pela descarbonização no tratamento térmico de lodo para geração de energia elétrica surge como uma solução promissora com profundas implicações ambientais, econômicas e sociais. Essa abordagem transformadora não apenas atende à necessidade urgente de reduzir as emissões de carbono, mas também destaca o potencial de transformar um fluxo de resíduos em um recurso valioso.

Ao aproveitar a energia latente no lodo por meio de tratamentos térmicos avançados, não apenas contribuímos para a diversificação das fontes de energia, como também aliviemos a pressão sobre a geração de energia tradicional baseada em combustíveis fósseis. Essa mudança está alinhada aos esforços globais para combater as mudanças climáticas e promove uma infraestrutura energética mais sustentável e resiliente.

Os avanços tecnológicos nos processos de conversão de lodo em energia desempenham um papel fundamental na obtenção de resultados eficientes e ambientalmente sustentáveis. A pesquisa e a inovação contínuas serão essenciais para otimizar esses métodos, minimizando o impacto ambiental, aumentando a recuperação de energia e garantindo a viabilidade econômica. Além disso, o sucesso da descarbonização nos tratamentos térmicos de lodo depende de esforços colaborativos entre governos, representantes da indústria e o público. Políticas, regulamentações e incentivos devem ser alinhados para encorajar a adoção generalizada de tecnologias mais limpas, fomentando um ambiente favorável a práticas sustentáveis.

À medida que navegamos pelas complexidades da transição energética, a integração do tratamento térmico de lodo no panorama mais amplo das fontes de energia renováveis torna-se imperativa. Essa abordagem holística não só contribui para a redução das emissões de gases de efeito estufa, como também promove um portfólio energético diversificado e resiliente. Em essência, a descarbonização do tratamento térmico de lodo representa um passo proativo e estratégico rumo a um futuro mais sustentável. Ao repensarmos os resíduos como um recurso valioso e ao adotarmos tecnologias inovadoras, podemos pavimentar o caminho para um mundo mais limpo, mais verde e com maior segurança energética.

Com base na visão geral abrangente apresentada, fica claro que o avanço dos tratamentos térmicos de lodo requer não apenas o aprimoramento contínuo de tecnologias essenciais, como pirólise, gaseificação e co-combustão, mas também a integração perfeita do monitoramento em tempo real e do controle baseado em dados. A implantação de redes de sensores robustas permite o rastreamento contínuo de parâmetros críticos (temperatura, pressão, vazão), que, quando combinados com análises baseadas em IA, podem otimizar dinamicamente as condições do reator para maximizar a recuperação de energia e minimizar as emissões de carbono.

A colaboração entre governos, concessionárias de serviços públicos, fornecedores de tecnologia e a comunidade científica será essencial para alinhar os mercados de energia, os mecanismos de precificação de carbono e os programas de financiamento, catalisando assim a adoção em larga escala de tratamentos térmicos mais limpos e transformando o lodo de esgoto de um passivo de descarte em um ativo estratégico de energia e recursos.

O monitoramento de processos em tempo real por meio de redes de sensores avançadas, aliado à inteligência artificial para modelagem preditiva e controle adaptativo, apresenta-se como uma via promissora para melhorar a eficiência operacional, reduzir emissões e facilitar a otimização dinâmica em sistemas de conversão de lodo em energia. Além disso, a pesquisa deve se concentrar na valorização de subprodutos como biochar, gás de síntese e cinzas ricas em fósforo, fomentando uma economia circular por meio do desenvolvimento de aplicações

padronizadas e prontas para o mercado. Por fim, avaliações abrangentes do ciclo de vida e análises técnico-econômicas são necessárias para validar a sustentabilidade a longo prazo e a viabilidade financeira dessas tecnologias, enquanto estudos voltados para políticas públicas devem explorar incentivos regulatórios e mecanismos de crédito de carbono que apoiem sua ampla adoção. Em conjunto, essas direções oferecem um roteiro de pesquisa coerente para transformar o tratamento térmico de lodo em um pilar da infraestrutura de energia sustentável e gestão de resíduos.

Neste capítulo foram determinadas rotas que serão avaliadas no decorrer da tese, que podem ser alternativas de produtos no setor elétrico e que podem ser otimizadas dentro de usinas por algoritmos de controle, sendo potenciais pesquisas que podem se tornar trabalhos futuros para tese ou no desenvolvimento do modelo de negócio em usinas termelétricas de biomassa.

3 ALGORITMOS BASEADOS EM INTELIGÊNCIA ARTIFICIAL

Neste capítulo são apresentados os métodos de IA para aplicações relacionadas a avaliação do sistema elétrico, assim como seus resultados em uma análise quantitativa que visa a identificação da estrutura mais adequada para aplicação ao problema apresentado. Para a avaliação dos modelos analisados aqui, foram considerados o erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE), erro percentual absoluto médio (MAPE), MAPE simétrico (SMAPE), e coeficiente de determinação (R^2), dados por:

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

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

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

$$\text{SMAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i + \hat{y}_i|)/2} \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

onde y é o valor observado, \hat{y} é o valor previsto, \bar{y} é a média do valor observado e n é o número de amostras (SEMAN *et al.*, 2023).

3.1 CNN-LSTM PARA PREVISÃO

A previsão de séries temporais de geração de eletricidade em sistemas térmicos alimentados por biomassa envolve a previsão da produção futura de eletricidade com base em padrões de dados históricos (RAHMAN *et al.*, 2021). Estas previsões são cruciais para otimizar a produção de energia, gerir recursos de forma eficiente e planejar a demanda futura (RIBEIRO *et al.*, 2020b). Ao analisar tendências passadas no consumo de biomassa, condições meteorológicas, eficiência das instalações e outros factores relevantes, os modelos preditivos podem ser aplicados para antecipar os níveis futuros de produção de electricidade. Isto permite que as partes interessadas

decidam sobre estratégias de produção, distribuição e investimento de energia. Além disso, os avanços em ML e a análise de dados melhoraram a precisão e a confiabilidade destas previsões (BRANCO; CAVALCA; OVEJERO, 2024), facilitando práticas de gestão de energia sustentável e promovendo a integração de recursos energéticos renováveis na rede energética.

Um desafio na aplicação destes modelos é a seleção da arquitetura apropriada. Existem modelos baseados em aprendizagem profunda, alternativas promissoras nesta área (STEFENON *et al.*, 2022). Além dos modelos que exigem maior esforço computacional, modelos rasos também têm sido aplicados neste campo de estudo (MEDEIROS *et al.*, 2022). Dentre as abordagens de predição, os modelos híbridos têm sido uma alternativa promissora na previsão de séries temporais. A extração de características por meio de redes neurais convolucionais (CNN) juntamente com abordagens de previsão como memória de longo e curto prazo (LSTM) resultam em modelos que superam estruturas clássicas e estão sendo cada vez mais explorados (DENG; CHEN; HUANG, 2022).

As CNNs são excelentes na captura de padrões espaciais e características locais, enquanto as LSTMs são especializadas na modelagem de dependências temporais. Ao integrar esses dois componentes, a arquitetura CNN-LSTM pode lidar efetivamente com dados de séries temporais complexos ou ruidosos, tornando-os mais robustos a variações e flutuações nos dados de entrada (LIVIERIS; PINTELAS; PINTELAS, 2020). Essa robustez é particularmente valiosa em aplicações do mundo real onde os dados podem estar incompletos ou sujeitos a ruído (XIE; ZHANG; LIM, 2020).

Um benefício do modelo CNN-LSTM é sua capacidade de extração automática de recursos. Ao contrário dos métodos de previsão padrão que geralmente exigem engenharia de recursos, as CNNs podem aprender recursos relevantes automaticamente a partir das sequências de entrada (SONG *et al.*, 2021). Isso reduz a necessidade de conhecimento de domínio e intervenção humana no processo de extração de recursos, tornando o modelo mais escalonável e adaptável a diferentes tipos de dados de séries temporais (WANG *et al.*, 2020).

3.1.1 Arquitetura do CNN-LSTM

A previsão de séries temporais desempenha um papel importante nos processos de tomada de decisão em vários setores (LIU *et al.*, 2021). Os métodos tradicionais podem ter dificuldades para capturar os padrões intrincados presentes nos dados de séries temporais do mundo real (LIU *et al.*, 2023b). Com os avanços em DL, arquiteturas mais complexas foram desenvolvidas para lidar com as complexidades dos dados de séries temporais, como os LSTMs (TORRES; MARTÍNEZ-ÁLVAREZ; TRONCOSO, 2022).

Os LSTMs são equipados com células de memória e mecanismos de controle que lhes permitem lembrar ou esquecer dados seletivamente em longas sequências. Esta capacidade torna os LSTMs particularmente adequados para tarefas de previsão de séries temporais (BARETH *et al.*, 2024), onde a compreensão das dependências de longo alcance é crucial (LI *et al.*, 2022).

As CNNs são poderosas na captura de padrões espaciais em dados. Em relação à previsão

de séries temporais, CNNs unidimensionais são empregadas para aprender automaticamente recursos relevantes a partir de dados sequenciais. Estas características podem representar padrões ou motivos dentro da série temporal, tais como tendências locais ou estruturas repetidas (MAHMOUD; MOHAMMED, 2021). As camadas CNN operam deslizando um conjunto de filtros (kernels) sobre a sequência de entrada, extraindo recursos por meio de convoluções e aplicando funções de ativação não linear (SINGH; STEFENON; YOW, 2023).

As camadas CNN servem como extratores de recursos, capturando padrões relevantes dos dados de série temporal de entrada. Esses recursos extraídos são então alimentados nas camadas LSTM, que modelam a dinâmica temporal e as dependências para fazer previsões precisas (KASBURG; STEFENON, 2019). Ao combinar CNNs e LSTMs, o modelo pode aprender representações hierárquicas dos dados de entrada, capturando padrões locais e globais.

As camadas LSTM na arquitetura CNN-LSTM recebem as representações de recursos extraídas pelas camadas CNN e modelam ainda mais a natureza sequencial dos dados, aprendendo a prever valores futuros com base nos padrões e dependências aprendidos (BORRÉ *et al.*, 2023). Ao incorporar camadas LSTM, o modelo pode capturar relacionamentos e dependências complexas que abrangem vários intervalos de tempo. Essa capacidade de capturar dependências de longo alcance é crucial para previsões precisas, especialmente em cenários onde as informações históricas impactam significativamente as previsões futuras (YUSUF *et al.*, 2021).

Os parâmetros que podem ser aprendidos de uma camada LSTM incluem os pesos de entrada W , os pesos recorrentes R , e o viés b . Os W , R e b são, respectivamente, as concatenações dos pesos de entrada e recorrentes, e os vieses de cada componente, como segue:

$$W = \begin{matrix} W_i & R_i & b_i \\ W_f & R_f & b_f \\ W_g & R_g & b_g \\ W_o & R_o & b_o \end{matrix}, \quad R = \begin{matrix} R_f \\ R_g \\ R_o \end{matrix}, \quad b = \begin{matrix} b_f \\ b_g \\ b_o \end{matrix}. \quad (7)$$

Para prever uma sequência, as respostas das sequências de treinamento são avançadas em uma etapa única. Consequentemente, em cada ponto da sequência de entrada, o modelo LSTM assume a tarefa de prever o valor do passo de tempo subsequente (MAN *et al.*, 2023). Neste trabalho, otimizadores SGD, Adam e RMSprop foram utilizados.

Ao aprender representações hierárquicas, extrair recursos automaticamente, capturar dependências de longo prazo e aprimorar a robustez do modelo, o CNN-LSTM fornece uma estrutura poderosa para modelar padrões temporais complexos (XU *et al.*, 2024). Espera-se que mais pesquisas em CNN-LSTM e arquiteturas relacionadas impulsionem o progresso contínuo em aplicações de previsão de séries temporais em vários domínios (ZHANG *et al.*, 2021). Além do CNN-LSTM, este experimento propõe uma etapa de filtragem. Após o ajuste do modelo, um filtro baseado na transformada wavelet é aplicado para remoção de ruído do sinal.

3.1.2 Remoção de Ruído Através da Transformada Wavelet

A transformada wavelet é aplicada para eliminar ruído de sinais de séries temporais, reduzindo as altas frequências do sinal. Sua aplicação é baseada na decomposição e reconstrução de pacotes wavelet. Neste procedimento, o sinal reconstruído possui menos não-linearidades que o sinal original, o que é uma característica vantajosa para ser aplicada na previsão de séries temporais (STEFENON *et al.*, 2021).

A técnica de pacote wavelet é um ramo da decomposição wavelet para extrair características do sinal. Pacotes wavelet são formas de onda indexadas por posição, frequência e escala. A decomposição wavelet pode ser expressa como:

$$W_{\Psi, X}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \Psi * \left(\frac{t-b}{a} \right) dt, \quad a \neq 0 \quad (8)$$

onde, $x(t)$ é o sinal decomposto, a e b são, respectivamente, os parâmetros de escala e deslocamento, e $\Psi(t)$ é a wavelet mãe (STEFENON *et al.*, 2020b). Considerando uma discretização, a wavelet mãe $\Psi(n)$ e a função de escala $\Phi(n)$ são dadas por:

$$\Psi(n) = \sum_{i=0}^{N-1} g(i) \Phi(2n-i), \quad (9)$$

$$\Phi(n) = \sum_{i=0}^{N-1} h(i) \Phi(2n-i). \quad (10)$$

Neste capítulo o modelo wavelet CNN-LSTM é proposto e realizada uma análise comparativa com os seguintes algoritmos: modelo CNN-LSTM original (SHI *et al.*, 2024), o predictor profundo não paramétrico de séries temporais de última geração (DeepNPTS) (RANGAPURAM *et al.*, 2023), TCN (HEWAGE *et al.*, 2020), interpolação hierárquica neural para séries temporais (NHITS) (CHALLU *et al.*, 2023), e os modelos de análise de expansão de base neural (NBEATS) (OLIVARES *et al.*, 2023).

3.1.3 Base de Dados para o Experimento

O Operador Nacional do Sistema (ONS) brasileiro é responsável pela coordenação e gestão da operação das instalações de geração e transmissão de energia elétrica no âmbito do Sistema Interligado Nacional. Também planeja a operação dos sistemas isolados do país, todos sob supervisão e regulação da Agência Nacional de Energia Elétrica (La Picirelli de Souza *et al.*, 2023). O ONS é composto por membros associados e participantes, incluindo empresas de geração, transmissão e distribuição, consumidores livres e importadores e exportadores de energia¹.

¹ Informações sobre a organização em: <<https://dados.ons.org.br/organizaÃ§Ã£o/sobre/ons>> (em português)

O planejamento da operação do sistema elétrico brasileiro é atualmente realizado em duas etapas, utilizando o DECOMP e o modelo NEWAVE, definido pelo ONS. DECOMP é um modelo computacional de otimização para planejamento da operação energética de curto prazo de sistemas hidrotérmicos e eólicos. Pode refinar, a política operacional é construída pelo NEWAVE (modelo de médio prazo), considerando aspectos mais detalhados das hidrelétricas, das termelétricas e do sistema de transmissão (SANTOS *et al.*, 2020).

Considerando a incerteza nas afluições e a aversão ao risco estes modelos garantem um despacho robusto e, conseqüentemente, a política operacional mais adequada para a programação diária da operação do sistema (BRITO *et al.*, 2022). O DECOMP utiliza uma janela de tempo de observação de 3 meses para fazer a previsão horária de curto prazo. Considerando que o foco deste trabalho é a previsão de curto prazo, este trabalho assume o mesmo período de análise.

A base de dados utilizada baseia-se na geração verificada de usinas, conjuntos de usinas e grupos de pequenas centrais por hora, disponibilizada pelo ONS². Especialmente para este estudo de caso, os dados foram filtrados para geração baseada em biomassa, com um total de 58 usinas conectadas ao sistema elétrico nacional. A soma da geração de energia resulta em uma série temporal que representa o total de energia gerada pela biomassa no Brasil, esta série temporal é apresentada na Figura 8. Para avaliação horária da variação da energia gerada pela biomassa foram considerados três meses (contendo um total de 2.208 registros, de 0h do dia 09 de janeiro de 2024 a 23h do dia 09 de maio de 2024).

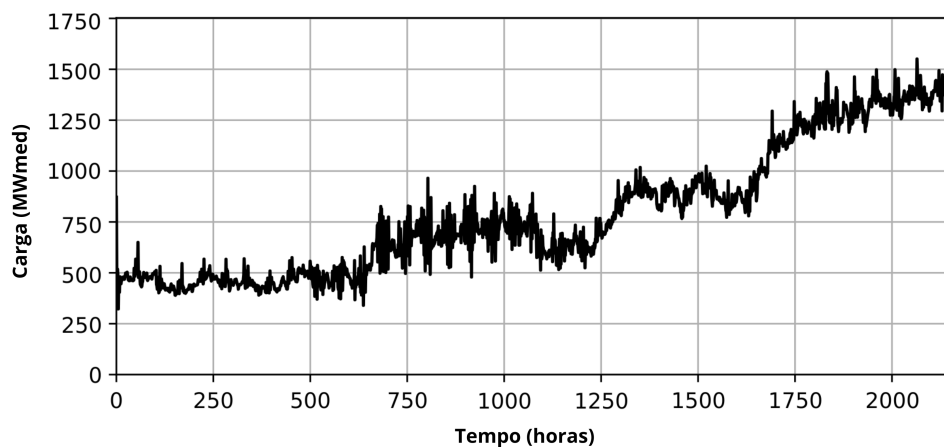


Figura 8 – Geração de energia da biomassa em relação ao tempo.

Fonte: Adaptado de (BURATTO *et al.*, 2024b)

Do total de termelétricas a biomassa instaladas no Brasil, cinco estão localizadas na região Norte, duas no Nordeste, uma no Sul e 49 no Sudeste. Considerando que o Sudeste é a região mais industrializada do país, uma das principais vantagens das termelétricas é a possibilidade de instalá-las próximas aos grandes centros consumidores. Como o sistema nacional está interligado,

² Para análises futuras, os dados podem ser encontrados em: <<https://dados.ons.org.br/dataset/geracao-usina-2>>.

a avaliação da geração de biomassa apresentada neste trabalho considera a soma de todas as 58 usinas.

3.1.4 Resultados e Discussões

Nesta seção, os resultados do wavelet CNN-LSTM são apresentados e comentados. Os experimentos consideraram uma unidade de processamento gráfico NVIDIA T4 com 16 GB de memória, o algoritmo foi escrito em Python e os cálculos foram feitos usando o backend do mecanismo de computação do Google (`colab.google`). Considerando que o modelo pode começar a superajustar, aplica-se o stop antecipado. Quando a perda de validação não melhora em comparação com a perda de treinamento, o modelo interrompe o treinamento. Para efeito de comparação, considera-se o máximo de 100 épocas, e a parada precoce ocorre quando há mais de 20 épocas sem melhora (paciência). Um exemplo de overfitting é apresentado na Figura 9.

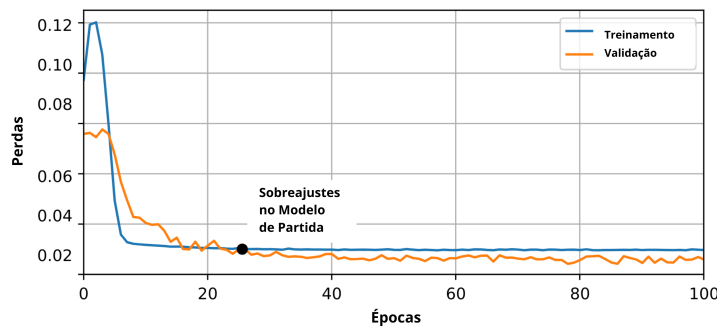


Figura 9 – Perdas durante treinamento.
Fonte: Adaptado de (BURATTO *et al.*, 2024b)

3.1.5 Avaliação do Modelo CNN-LSTM

A avaliação apresentada nesta subseção está focada em identificar os parâmetros corretos para o melhor comprometimento no modelo. A análise do método CNN-LSTM começa com a relação percentual entre a divisão dos dados para treinamento e teste e o horizonte observado para previsão. Um exemplo dos resultados comparando os valores observados e previstos do CNN-LSTM é mostrado na Figura 10, considerando 90% dos dados para treinamento e 10% dos dados para teste.

A divisão dos dados e o horizonte podem ter uma grande influência nos resultados. Uma avaliação considerando diferentes horizontes e diferentes divisões de dados, é apresentada na Tabela 4. As métricas de avaliação de erros aqui utilizadas visam verificar o menor erro de predição possível, dados os parâmetros de configuração avaliados.

Para este modelo, a utilização de diferentes horizontes de previsão não resultou numa alteração significativa no desempenho, mas a utilização de menos dados de treino teve impacto no desempenho do modelo. Para todos os horizontes avaliados, a utilização de 90% dos dados




Figura 10 – Resultados comparativos do valores previstos pelo modelo CNN-LSTM e valores observados.

Fonte: Adaptado de (BURATTO *et al.*, 2024b)

Tabela 4 – Avaliação da proporção de divisão de dados para treinar e testar o modelo e o horizonte de previsão.

Horizonte	Taxa	RMSE	MAE	MAPE	SMAPE	R ²	Tempo (s)
5	70/30	2.98×10^2	2.54×10^2	1.83×10^{-1}	2.07×10^1	2.19×10^{-1}	1.44×10^2
	80/20	1.13×10^2	9.47×10^1	6.91×10^{-2}	7.25	1.47×10^{-1}	8.72×10^1
	90/10	5.69×10^1	4.20×10^1	3.05×10^{-2}	3.12	1.53×10^{-1}	4.49×10^2
10	70/30	3.16×10^2	2.70×10^2	1.95×10^{-1}	2.21×10^1	3.73×10^{-1}	1.47×10^2
	80/20	1.14×10^2	9.55×10^1	6.95×10^{-2}	7.29	2.75×10^{-1}	1.71×10^2
	90/10	7.88×10^1	6.40×10^1	4.63×10^{-2}	4.79	5.88×10^{-1}	3.68×10^2
15	70/30	2.90×10^2	2.48×10^2	1.79×10^{-1}	2.01×10^1	1.79×10^{-1}	2.93×10^2
	80/20	1.11×10^2	9.34×10^1	6.80×10^{-2}	7.12	3.11×10^{-1}	2.51×10^2
	90/10	5.26×10^1	3.83×10^1	2.79×10^{-2}	2.84	3.09×10^{-1}	1.93×10^2
20	70/30	2.63×10^2	2.27×10^2	1.66×10^{-1}	1.83×10^1	1.85×10^{-2}	8.15×10^1
	80/20	1.33×10^2	1.15×10^2	8.40×10^{-2}	8.88	1.00	1.81×10^2
	90/10	4.77×10^1	3.49×10^1	2.58×10^{-2}	2.59	4.30×10^{-1}	2.04×10^2
25	70/30	2.24×10^2	1.97×10^2	1.46×10^{-1}	1.57×10^1	2.71×10^{-1}	1.59×10^2
	80/20	1.49×10^2	1.34×10^2	9.82×10^{-2}	1.04×10^1	1.59	2.76×10^2
	90/10	5.16×10^1	3.89×10^1	2.92×10^{-2}	2.89	3.54×10^{-1}	2.05×10^2

para treinamento trouxe resultados superiores com menor erro de previsão, considerando que uma previsão com 10% dos dados é adequada para teste, este valor foi definido para todas as análises.

O melhor horizonte observado foi de 20 horas, razão pela qual este Horizonte foi considerado neste trabalho como o Horizonte adequado para avaliar a previsão energética. Inicialmente, para este experimento, foi considerado o otimizador Adam, com taxa de aprendizado igual a 1×10^{-3} , 1 camada e 4 unidades ocultas (HU). Para obter uma estrutura otimizada, esses parâmetros de configuração do modelo foram avaliados. A Tabela 5 mostra os resultados da variação das camadas e HU.

Tabela 5 – Avaliação do número de camadas e unidades escondidas no modelo de arquitetura.

Camadas	HU	RMSE	MAE	MAPE	SMAPE	R ²	Tempo (s)
1	1	5.34×10^1	3.97×10^1	2.89×10^{-2}	2.94	2.84×10^{-1}	3.70×10^2
	2	4.87×10^1	3.59×10^1	2.64×10^{-2}	2.66	4.05×10^{-1}	3.97×10^2
	3	5.10×10^1	3.77×10^1	2.76×10^{-2}	2.80	3.49×10^{-1}	1.99×10^2
	4	4.83×10^1	3.56×10^1	2.63×10^{-2}	2.64	4.16×10^{-1}	4.13×10^2
2	1	4.81×10^1	3.53×10^1	2.60×10^{-2}	2.62	4.21×10^{-1}	6.32×10^2
	2	4.82×10^1	3.56×10^1	2.62×10^{-2}	2.64	4.18×10^{-1}	6.77×10^2
	3	6.17×10^1	4.69×10^1	3.40×10^{-2}	3.48	4.44×10^{-2}	2.82×10^2
	4	5.94×10^1	4.48×10^1	3.25×10^{-2}	3.33	1.15×10^{-1}	5.86×10^2
3	1	8.31×10^1	6.75×10^1	4.89×10^{-2}	5.07	7.31×10^{-1}	3.28×10^2
	2	5.55×10^1	4.17×10^1	3.05×10^{-2}	3.09	2.28×10^{-1}	7.02×10^2
	3	7.03×10^1	5.50×10^1	3.98×10^{-2}	4.10	2.38×10^{-1}	3.67×10^2
	4	6.44×10^1	4.91×10^1	3.56×10^{-2}	3.65	3.84×10^{-2}	3.76×10^2
4	1	8.73×10^1	7.10×10^1	5.14×10^{-2}	5.34	9.10×10^{-1}	5.82×10^2
	2	6.56×10^1	5.01×10^1	3.63×10^{-2}	3.73	7.81×10^{-2}	8.41×10^2
	3	5.53×10^1	4.16×10^1	3.04×10^{-2}	3.08	2.34×10^{-1}	1.05×10^3
	4	5.95×10^1	4.49×10^1	3.26×10^{-2}	3.33	1.14×10^{-1}	8.94×10^2

A variação no número de camadas e HU resultou em uma pequena variação nos resultados do modelo, e a configuração inicial teve um resultado satisfatório, mostrando que o modelo foi inicialmente bem desenhado. Nesta análise comparativa, o melhor resultado foi utilizar 2 camadas e 1 unidade oculta para cada uma dessas camadas, e este resultado foi utilizado como arquitetura padrão para as análises seguintes.

Utilizar mais camadas e uma estratégia de rede mais profunda não trouxe resultados promissores, razão pela qual esta abordagem não foi utilizada. Considerando a melhor seleção de dados e arquitetura do modelo, é apresentada na Tabela 6 uma análise para avaliar o otimizador e a taxa de aprendizagem (LR) utilizada no modelo CNN-LSTM, sendo estes os últimos parâmetros do modelo a serem avaliados.

A utilização de um LR inadequado prejudica consideravelmente o treinamento do modelo, e os resultados de desempenho são afetados negativamente quando valores de LR muito altos ou baixos são utilizados. O melhor resultado nesta avaliação foi com o otimizador Adam e um LR de 1×10^{-3} , que foram os parâmetros inicialmente utilizados nesta avaliação. Isso comprova que o desenho da arquitetura foi bem feito e que a variação nos parâmetros do modelo resultou na redução do seu desempenho.

O objetivo da avaliação apresentada nas Tabelas 4 a 6 é definir os melhores parâmetros para configurar o modelo para que ele atinja seu melhor desempenho. Especificamente, a melhor configuração de uso de dados referente ao horizonte de predição é avaliada na Tabela 3, enquanto a Tabela 4 mostra a influência da mudança na arquitetura do modelo (uso de camadas mais profundas e mais unidades ocultas) e, por fim, a Tabela 5 avalia as configurações do otimizador.

Os resultados comparativos entre os valores previstos e observados mostram que o modelo tem maior dificuldade em prever variações abruptas, o que é esperado visto que essas

Tabela 6 – Avaliação do otimizador e modelo de taxa de aprendizado.

Otimizador	LR	RMSE	MAE	MAPE	SMAPE	R ²	Time (s)
Adam	1×10^{-1}	1.30×10^2	1.14×10^2	8.33×10^{-2}	8.79	3.24	1.37×10^2
	1×10^{-2}	1.19×10^2	1.03×10^2	7.47×10^{-2}	7.85	2.56	6.06×10^2
	1×10^{-3}	4.74×10^1	3.45×10^1	2.56×10^{-2}	2.56	3.98×10^{-1}	4.35×10^2
	1×10^{-4}	6.09×10^1	4.65×10^1	3.37×10^{-2}	3.46	7.02×10^{-2}	6.17×10^2
	1×10^{-5}	6.53×10^2	6.50×10^2	4.84×10^{-1}	6.39×10^1	1.06×10^2	1.31×10^2
RMSprop	1×10^{-1}	7.72×10^1	6.41×10^1	4.88×10^{-2}	4.75	4.94×10^{-1}	5.17×10^2
	1×10^{-2}	7.96×10^1	6.18×10^1	4.48×10^{-2}	4.62	5.90×10^{-1}	1.16×10^2
	1×10^{-3}	7.81×10^1	6.09×10^1	4.40×10^{-2}	4.55	5.31×10^{-1}	3.28×10^2
	1×10^{-4}	9.91×10^1	8.46×10^1	6.15×10^{-2}	6.41	1.46	4.42×10^2
	1×10^{-5}	7.93×10^2	7.90×10^2	5.88×10^{-1}	8.34×10^1	1.56×10^2	5.30×10^2
SGD	1×10^{-1}	8.09×10^1	6.78×10^1	5.17×10^{-2}	5.01	6.40×10^{-1}	1.04×10^2
	1×10^{-2}	1.14×10^2	9.75×10^1	7.08×10^{-2}	7.43	2.27	1.82×10^2
	1×10^{-3}	1.36×10^2	1.20×10^2	8.79×10^{-2}	9.29	3.62	9.67×10^1
	1×10^{-4}	1.88×10^2	1.77×10^2	1.30×10^{-1}	1.40×10^1	7.88	4.53×10^2
	1×10^{-5}	7.52×10^2	7.50×10^2	5.58×10^{-1}	7.74×10^1	1.41×10^2	9.41×10^1

variações não são esperadas, e o modelo tem que utilizar os valores médios históricos para treinamento. Uma possível forma de melhorar esses resultados seria utilizar filtros que atenuassem os valores observados, desconsiderando variações bruscas. Neste trabalho, os sinais originais foram considerados para que um modelo pudesse ser utilizado diretamente nesta avaliação.

3.1.6 Avaliação Estatística

Observando que houve variabilidade nos resultados, considerando uma inicialização aleatória dos pesos da rede neural, uma análise estatística é apresentada nesta subseção. Para avaliar a variabilidade da rede neural, foram realizados 50 experimentos com inicialização aleatória, para avaliar se o modelo apresenta variação significativa em seus resultados de erro caso mais experimentos sejam avaliados. O resultado da análise estatística considerando estes experimentos é mostrado na Tabela 7.

A avaliação estatística apresentada na Tabela 7 visa verificar se os parâmetros definidos de acordo com os resultados das Tabelas 4 a 6 são adequados para que o modelo seja estável à variação de pesos causada por a inicialização aleatória da rede.

Para uma visualização mais clara da variabilidade dos resultados nos 50 experimentos, a Figura 11 mostra gráficos representando a variabilidade do erro para todos os experimentos. Como pode ser observado, a grande maioria dos resultados ficou próxima da média, demonstrando que o modelo é confiável e não é afetado pela inicialização aleatória dos pesos da rede neural. Observando a Figura 11, com um MAPE médio de 0,0259 considerando 50 execuções, o método proposto é muito promissor para a previsão da geração de energia elétrica considerando sistemas térmicos de biomassa.

A Figura 11 esclarece que o modelo é estável, uma vez que não existem valores discrepantes significativos. Isso mostra que o modelo foi configurado corretamente e não está vulnerável à

Tabela 7 – Avaliação estatística.

	RMSE	MAE	MAPE	SMAPE	R ²
Média	4.80×10^1	3.50×10^1	2.59×10^{-2}	2.60	4.23×10^{-1}
Mediana	4.78×10^1	3.49×10^1	2.58×10^{-2}	2.59	4.28×10^{-1}
Mode	4.73×10^1	3.43×10^1	2.54×10^{-2}	2.54	3.80×10^{-1}
Faixa	2.45	2.50	2.17×10^{-3}	1.88×10^{-1}	5.95×10^{-2}
Desvio padrão	6.84×10^{-1}	6.82×10^{-1}	5.59×10^{-4}	5.10×10^{-2}	1.66×10^{-2}
25th% percentil	4.74×10^1	3.44×10^1	2.55×10^{-2}	2.55	4.19×10^{-1}
50th% percentil	4.78×10^1	3.49×10^1	2.58×10^{-2}	2.59	4.28×10^{-1}
75th% percentil	4.81×10^1	3.52×10^1	2.60×10^{-2}	2.61	4.37×10^{-1}
IQR	7.17×10^{-1}	8.39×10^{-1}	5.08×10^{-4}	6.23×10^{-2}	1.72×10^{-2}




Figura 11 – Plotagens em formatos de violinos dos erros avaliados considerando 50 execuções.
 Fonte: Adaptado de (BURATTO *et al.*, 2024b)

inicialização aleatória das pessoas na rede. Considerando o modelo estável, a próxima subseção apresenta os resultados da utilização do filtro de transformada wavelet como etapa de dados de entrada para o modelo de predição.

3.1.7 Avaliação de Filtragem

A transformada wavelet deve ser aplicada sem perder as características do sinal, por isso é necessário avaliar cuidadosamente a resposta da transformada wavelet em relação ao sinal original. Uma alta atenuação do sinal pode resultar em um sinal decomposto que não representa os padrões de tendência do sinal original. Um exemplo do resultado da transformada wavelet é mostrado na Figura 12.

O principal parâmetro a ser definido na aplicação da transformada wavelet é o nível em

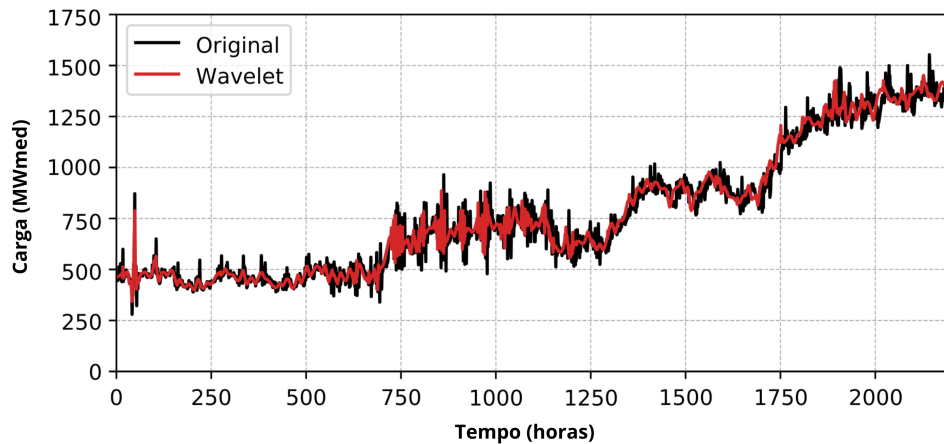


Figura 12 – Transformada Wavelet x valores observados.

Fonte: Adaptado de (BURATTO *et al.*, 2024b)

que ela é aplicada. Níveis superiores a 50 não resultaram em melhora significativa na filtragem do sinal, por isso não foram avaliados aqui. Os resultados da aplicação do modelo wavelet CNN-LSTM proposto variando o nível de filtragem (L) são mostrados na Tabela 8.

Tabela 8 – Análise de nível Wavelet.

L	RMSE	MAE	MAPE	SMAPE	R ²
1	3.60×10^1	2.70×10^1	1.98×10^{-2}	2.00	6.49×10^{-1}
2	4.59×10^1	3.81×10^1	2.77×10^{-2}	2.82	3.49×10^{-1}
3	3.41×10^1	2.62×10^1	1.90×10^{-2}	1.93	6.40×10^{-1}
4	2.89×10^1	2.48×10^1	1.85×10^{-2}	1.84	6.66×10^{-1}
5	2.62×10^1	2.24×10^1	1.65×10^{-2}	1.65	7.04×10^{-1}
10	2.31×10^1	1.97×10^1	1.45×10^{-2}	1.45	7.18×10^{-1}
20	2.57×10^1	2.17×10^1	1.59×10^{-2}	1.59	6.51×10^{-1}
30	2.71×10^1	2.26×10^1	1.65×10^{-2}	1.65	6.12×10^{-1}
40	2.48×10^1	2.10×10^1	1.55×10^{-2}	1.54	6.73×10^{-1}
50	2.54×10^1	2.15×10^1	1.58×10^{-2}	1.58	6.59×10^{-1}

Considerando o sinal utilizado, um nível superior a dez não resultou em melhora na decomposição, portanto este foi o valor definido a ser aplicado neste filtro. A comparação do sinal original versus o previsto usando um nível igual a dez é apresentada na Figura 13. Com base na utilização do modelo com seus parâmetros ajustados, uma análise comparativa do modelo wavelet CNN-LSTM proposto em comparação com outras estruturas é apresentada na próxima subseção.

3.1.8 Considerações Finais sobre o modelo CNN-LSTM

A integração das abordagens wavelet, CNN e LSTM para a previsão de séries temporais de geração de energia elétrica oferece um caminho promissor para melhorar a precisão e a




Figura 13 – Valores previstos pela Wavelet CNN-LSTM em relação aos valores observados.
Fonte: Adaptado de (BURATTO *et al.*, 2024b)

eficiência da previsão. Através da fusão de arquiteturas de redes neurais convolucionais e recorrentes, o CNN-LSTM permite a extração de características espaciais e temporais de fluxos de dados complexos, capturando assim padrões intrincados inerentes aos processos de geração de energia baseados em biomassa, aproveitando os pontos fortes inerentes de CNNs e LSTMs, como extração de recursos e modelagem de sequência. Esta metodologia facilita capacidades robustas de previsão cruciais para otimizar estratégias de geração e consumo de energia.

Dado um MAPE de 0,0148, a wavelet CNN-LSTM mostrou-se promissora para prever eletricidade a partir da geração de biomassa. A variação na quantidade de dados utilizados para treinar ou testar o modelo teve influência significativa nos resultados de desempenho, assim como o uso de outros otimizadores ou taxas de aprendizagem. Considerando o uso adequado desses parâmetros, o modelo apresentou resultados promissores nas avaliações apresentadas neste trabalho, mostrando-se um modelo robusto mesmo quando diversos experimentos são avaliados de acordo com a análise estatística aqui apresentada.

A utilização da transformada wavelet é uma solução interessante, pois reduz a complexidade da análise, uma vez que não são consideradas variações abruptas devido à filtragem do sinal. Utilizar um método híbrido que considera o sinal filtrado na entrada é uma abordagem promissora, validando o modelo proposto apresentado neste trabalho.

3.2 MÉTODO HÍBRIDO DE PROCESSAMENTO DE DADOS EM GRUPO PARA PREVISÃO DE SÉRIES TEMPORAIS DO DESPACHO DE GERAÇÃO TÉRMICA EM SISTEMAS DE ENERGIA ELÉTRICA

3.2.1 Introdução

O despacho de energia elétrica em sistemas de potência é determinado pela demanda do consumidor ao longo do tempo, portanto há a necessidade de prever o padrão de consumo de energia. (TALBI *et al.*, 2020).

No Brasil, o despacho do sistema elétrico é baseado em um problema de otimização estocástica, considerando horizontes de curto e longo prazo, onde a principal fonte de energia provém de usinas hidrelétricas (STEFENON *et al.*, 2022).

Nesse contexto, as usinas termelétricas são utilizadas quando os níveis dos reservatórios estão baixos, permitindo a regulação do sistema elétrico para garantir o fornecimento de energia ao longo do tempo (STEFENON *et al.*, 2023).

Considerando a necessidade de geração de energia para equilibrar o sistema elétrico e garantir o fornecimento ao longo do tempo, a geração térmica é despachada (KHAMLICH *et al.*, 2021). O despacho da geração térmica é uma questão crucial a ser avaliada, e é o foco deste artigo. Essa avaliação torna-se ainda mais desafiadora devido à variação do período chuvoso no Brasil (BRANCO *et al.*, 2022).

Avaliando estes desafios, o uso de modelos de inteligência artificial surge como uma solução promissora, dada a sua capacidade de lidar com padrões não lineares (STARKE *et al.*, 2023). As estruturas de aprendizado profundo estão ganhando destaque para essas aplicações (LARCHER *et al.*, 2024; AVCI *et al.*, 2021; STEFENON *et al.*, 2024a), no entanto, nem sempre são a melhor abordagem, pois exigem um alto esforço computacional, e, em alguns casos, redes rasas e métodos híbridos podem ser a melhor solução. (KLAAR *et al.*, 2023b).

Uma das principais vantagens da utilização de métodos híbridos é a capacidade de combinar as vantagens de múltiplas técnicas (STEFENON *et al.*, 2020a), neste trabalho em particular, o uso de filtros reduz as não linearidades do sinal. Como resultado, a previsão aqui proposta concentra-se na tendência de variação da série temporal, melhorando assim sua capacidade de previsão.

Propõe-se uma estrutura híbrida que combina o método de agrupamento de dados (GMDH) com técnicas de redução de ruído. As principais contribuições são:

- A primeira contribuição está relacionada ao uso de um modelo de adaptação cuja arquitetura é definida durante o treinamento, o que é promissor, pois utiliza apenas os neurônios relevantes para a realização da previsão.
- A segunda contribuição diz respeito ao uso de um método híbrido que combina a entrada do filtro para redução de ruído com o modelo de previsão, o qual supera a estrutura original e outros métodos de regressão de última geração.

Para a remoção de ruído do sinal, foram avaliados o filtro de Christiano Fitzgerald, o filtro de Hodrick-Prescott e a decomposição de tendência sazonal usando suavização de dispersão estimada localmente (LOESS). Para comparação, o método GMDH padrão, o transformador de fusão temporal (TFT), a rede convolucional temporal (TCN), a memória de longo prazo (LSTM) e o sistema adaptativo de inferência neuro-fuzzy (ANFIS) foram comparados ao método híbrido de manipulação de dados em grupo (HGMDH) proposto. Todos os modelos comparados foram utilizados com seus parâmetros de configuração padrão, definidos com base na literatura.

3.2.2 Metodologia

3.2.3 Estágio de redução de ruído de entrada

O método híbrido proposto consiste em integrar uma etapa adicional de redução de ruído na entrada ao modelo de predição. (RIBEIRO *et al.*, 2024). Como as séries temporais podem conter dados de alta frequência que não acompanham a tendência de variação da carga de energia, (SHI; TEH, 2024), essa variação de ruído pode ser atenuada por um estágio de redução de ruído na entrada, que será explicado aqui..

3.2.3.1 Filtro Christiano-Fitzgerald

O filtro de Christiano-Fitzgerald destaca-se como um método econométrico que proporciona maior flexibilidade na análise de dados de séries temporais, especialmente quando se trata de variáveis que apresentam tendências estocásticas ou comportamento não estacionário. Essa técnica foi projetada para estimar a componente de tendência, principalmente quando se exige uma compreensão mais profunda das características genuínas do processo subjacente (KUFENKO, 2020).

O filtro de Christiano-Fitzgerald é adequado para qualquer série temporal de uma única variável, denotada por Y_t , que possa ser expressa como uma caminhada aleatória. No modelo de caminhada aleatória, assume-se que a diferença em Y_t de um período para o seguinte, $Y_t - Y_{t-1}$, é uma variável aleatória com valor médio igual a zero (MORENO *et al.*, 2024). Uma representação do processo de caminhada aleatória é a seguinte:

$$Y_t = Y_{t-1} + \varepsilon_t, \quad (11)$$

Neste contexto, ε_t representa um termo de erro estocástico que é considerado independente e identicamente distribuído, apresentando uma média de zero e uma variância consistente. Com uma amostra fornecida $Y_{t=1}^T$, o objetivo é obter uma estimativa (\hat{Y}_t) do elemento não observado dentro da série temporal, frequentemente referido como tendência (BRANCO; CAVALCA; OVEJERO, 2024).

Este método envolve a projeção de Y_t no domínio de previsões lineares de d passos à frente e d passos atrás, onde o parâmetro d denota a largura de banda, exigindo uma seleção predeterminada. O filtro CFRW representa uma projeção linear:

$$\hat{Y}_t = \sum_{j=-d}^d \omega_j y_{t+j} \quad (12)$$

onde os pesos ω_j são derivados de um problema de minimização e dependem tanto de d quanto do padrão de autocorrelação dentro de Y_t . (STEFENON *et al.*, 2023b). Quando Y_t segue um padrão de caminhada aleatória, esses pesos ω_j tendem a se aproximar dos de um filtro passa-baixa à medida que o parâmetro d se aproxima do infinito.

3.2.3.2 Filtro Hodrick-Prescott

O filtro Hodrick-Prescott é um método usado para decompor uma série temporal em seus componentes de tendência e cíclicos. É particularmente útil para análise de séries temporais considerando o estudo de ciclos e tendências. O filtro Hodrick-Prescott separa uma série temporal (Y_t) em seus componentes de tendência (T_t) e cíclicos (C_t) usando a seguinte equação:

$$Y_t = T_t + C_t. \quad (13)$$

O filtro busca encontrar o componente de tendência T_t minimizando uma função de perda quadrática que penaliza as flutuações nas taxas de crescimento da tendência. O componente de tendência resultante representa a tendência subjacente mais suave nos dados da série temporal, enquanto o componente cíclico captura as flutuações de curto prazo em torno dessa tendência (SAKARYA; JONG, 2022).

A previsão de carga usando o filtro Hodrick-Prescott e o Google Trends foi verificada no sistema de energia da China por Wu et al. (WU; DOU; YUE, 2021), verificando que essa alternativa pode diminuir ou aumentar a precisão dos mecanismos de busca, dependendo do estudo de caso realizado em um longo período, quando aplicada em um curto espaço de tempo com o conjunto apropriado de previsões, a precisão de seus índices pode aumentar significativamente.

3.2.4 Decomposição da tendência sazonal usando LOESS

A decomposição de tendência sazonal usando suavização de dispersão estimada localmente (LOESS) é uma técnica utilizada para decompor uma série temporal em suas partes constituintes: componentes sazonais (S_t), de tendência e residuais (R_t). A decomposição é representada da seguinte forma:

$$Y_t = S_t + T_t + R_t. \quad (14)$$

A decomposição sazonal-tendência usando o método LOESS separa a série temporal Y_t em três componentes utilizando a técnica LOESS. O LOESS é um método de regressão não paramétrico que ajusta uma curva suave aos dados ponderando localmente pontos próximos, permitindo a modelagem flexível dos componentes sazonais e de tendência da série temporal (XU *et al.*, 2023).

O componente sazonal S_t representa os padrões ou ciclos recorrentes nos dados que se repetem em intervalos regulares. O componente de tendência T_t captura o comportamento ou a direção de longo prazo da série temporal. (HE *et al.*, 2021). O componente residual R_t representa a variabilidade ou ruído não explicado pelos componentes sazonais e de tendência. A decomposição sazonal-tendência usando LOESS é particularmente útil para analisar dados de séries temporais com padrões sazonais e de tendência, fornecendo uma maneira de extrair e analisar esses diferentes componentes separadamente (FICHTNER *et al.*, 2023).

3.2.5 Método de agrupamento de dados

Considerando uma série temporal, o modelo aprende a relação entre as defasagens. Tendo aprendido as relações, o GMDH seleciona a direção apropriada a seguir no algoritmo (CHEN *et al.*, 2021). Essa seleção é realizada automaticamente durante o treinamento; portanto, o teste utiliza apenas o melhor caminho identificado, considerando o número de camadas e o número de neurônios (HE *et al.*, 2023).

Um exemplo da arquitetura GMDH final, considerando esse procedimento, é apresentado na Figura 14.

Nessa arquitetura, x representa o sinal de entrada (um par de variáveis, por exemplo, x_1 e x_2), e y são as camadas ocultas principais. Os valores de y representam o sinal de entrada utilizado e o expoente indica a camada oculta; isso significa que y_1^1 é o neurônio da primeira camada oculta que considera a primeira entrada.

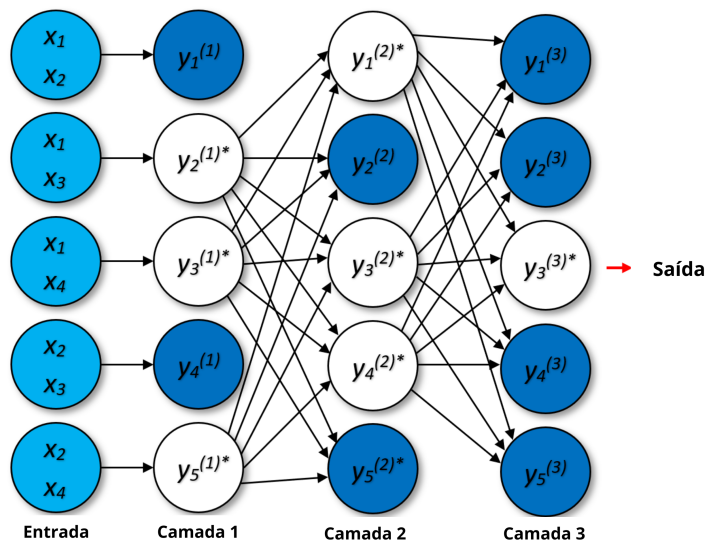


Figura 14 – Arquitetura do método híbrido de grupo para tratamento de dados.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

O pareamento de variáveis é uma função não linear, e os coeficientes são calculados aplicando-se modelos de regressão para cada par de variáveis de entrada, conforme mostrado:

$$\hat{y}(x_1, \dots, x_n) = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (15)$$

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (16)$$

onde i e j são cada par de variáveis de entrada (x_i e x_j), \hat{y} é o valor previsto do valor observado y (ARMAGHANI *et al.*, 2022). Os critérios de regularidade w são representados pela seguinte

equação:

$$w = \frac{\sum_{n=1}^P (\hat{y} - y)^2}{\sum_{n=1}^P (y)^2}. \quad (17)$$

onde P é o número de conjuntos de teste. Quando w não é reduzido em comparação com a camada anterior, o erro de previsão da rede não diminui mais. Dessa forma, a rede não se expande e o resultado da camada anterior é produzido. (SOBOLEWSKI; MICZULSKI, 2021). O coeficiente é determinado pelo erro quadrático médio (EQM) e o procedimento para calculá-lo é:

$$LSE = \begin{cases} \hat{y}(x_1, \dots, x_n) = G(x_i, x_j) \\ e = \sum_{n=1}^N (y - \hat{y})^2 \\ \frac{de}{da_k} = 0, \quad k = 1, 2, 3, 4, 5. \end{cases} \quad (18)$$

Os resultados podem ser apresentados em forma de matriz:

$$a = (X^T X)^{-1} X^T y \quad (19)$$

onde,

$$X = \begin{pmatrix} 1 & x_{i1} & x_{j1} & x_{i1}x_{j1} & x_{i1}^2 & x_{j1}^2 \\ 1 & x_{i2} & x_{j2} & x_{i2}x_{j2} & x_{i2}^2 & x_{j2}^2 \\ 1 & x_{i3} & x_{j3} & x_{i3}x_{j3} & x_{i3}^2 & x_{j3}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{in} & x_{jn} & x_{in}x_{jn} & x_{in}^2 & x_{jn}^2 \end{pmatrix}. \quad (20)$$

Durante o treinamento, o modelo é organizado para ter uma estrutura otimizada que atenda às necessidades de avaliação. Para obter uma estrutura aprimorada, a série temporal de entrada passa por um processo de remoção de ruído. Essa etapa é explicada na próxima subseção.

3.2.6 Comparação de modelos

Para fins de comparação, o método proposto é comparado aos modelos TFT, TCN, LSTM, ANFIS e ao GMDH original. Para uma comparação justa, esses modelos são avaliados com e sem o filtro.

3.2.6.1 TFT

O TFT é um modelo de aprendizado profundo projetado especificamente para previsão de séries temporais interpretável e de alto desempenho. O TFT combina diversos componentes poderosos: mecanismos de atenção, camadas de gating e redes neurais recorrentes. Ele é capaz de capturar tanto padrões temporais de curto prazo quanto dependências de longo prazo, além de lidar com covariáveis estáticas (que não mudam ao longo do tempo), entradas futuras conhecidas

e dados observados no passado. O TFT aprende a prever valores futuros ao selecionar partes relevantes da sequência de entrada, melhorando tanto a precisão quanto a interpretabilidade (NAZIR *et al.*, 2023).

Uma característica marcante do TFT é sua interpretabilidade. Ele emprega redes de seleção de variáveis que aprendem a importância relativa de cada variável de entrada, permitindo que os profissionais entendam quais entradas contribuem mais para a previsão. Além disso, o modelo utiliza camadas de atenção para destacar quais intervalos de tempo são mais influentes na geração de previsões, facilitando o diagnóstico e a confiabilidade do processo de previsão. Essa combinação de alta precisão e transparência do modelo torna o TFT ideal para tarefas complexas de previsão de séries temporais multivariadas em diversos domínios. (LIM *et al.*, 2021).

3.2.6.2 TCN

As TCNs (Redes Neurais Convolucionais) são um tipo de arquitetura de rede neural que aplica camadas convolucionais a dados sequenciais, tornando-as ideais para previsão de séries temporais. As TCNs utilizam convoluções causais dilatadas que permitem ao modelo acessar um amplo campo receptivo, capturando efetivamente dependências de longo alcance na série temporal, enquanto mantém a ordem temporal dos dados. O aspecto causal garante que as previsões para o instante de tempo t dependam apenas dos dados dos instantes de tempo $\leq t$, o que é crucial para prever valores futuros sem antecipar o futuro (LI *et al.*, 2023b).

Uma das principais vantagens das TCNs é o seu paralelismo e estabilidade durante o treinamento. Como as convoluções podem ser computadas em paralelo, as TCNs são mais rápidas de treinar e mais fáceis de otimizar. O uso de conexões residuais ajuda o modelo a aprender hierarquias profundas de características sem o problema do desaparecimento do gradiente. As TCNs têm demonstrado um desempenho robusto em diversas tarefas de previsão, particularmente onde padrões de longo prazo são importantes e a eficiência do treinamento é uma prioridade. Sua capacidade de modelar estruturas temporais complexas as torna uma alternativa poderosa aos modelos recorrentes para previsão de séries temporais (HEWAGE *et al.*, 2020).

3.2.6.3 LSTM

A LSTM é uma arquitetura de rede neural recorrente projetada para capturar dependências de longo alcance em dados sequenciais, tornando-a particularmente adequada para previsão de séries temporais. A LSTM compreende células de memória que permitem que a rede armazene informações por longos períodos. (SAGHEER; KOTB, 2019). Para um determinado passo de tempo t , o LSTM processa uma entrada x_t e atualiza seu estado interno.

Na LSTM, o portão de entrada (i_t) controla o fluxo de informações para a célula de memória. Ele decide quais valores da entrada x_t devem ser armazenados na célula. O portão de esquecimento (f_t) determina quais informações do estado anterior da célula c_{t-1} devem ser descartadas ou esquecidas. O estado da célula (c_t) representa a memória interna da célula e é

atualizado usando o portão de entrada, o portão de esquecimento e um novo valor candidato. O portão de saída (o_t) regula as informações que são emitidas pela célula. Ele decide quais partes do estado da célula devem ser expostas como a saída h_t .

A LSTM processa sequências de entrada passo a passo, atualizando seu estado interno de acordo. O treinamento de uma LSTM envolve alimentá-la com sequências de pares de entrada-saída (x_t, y_t) e ajustar seus parâmetros para minimizar uma função de perda. Isso normalmente envolve retropropagação no tempo e descida de gradiente.

As redes LSTM provaram ser eficazes na captura de dependências temporais em dados de séries temporais. Sua capacidade de aprender padrões de longo prazo as torna adequadas para diversas aplicações. (YADAV; JHA; SHARAN, 2020).

3.2.6.4 ANFIS

O ANFIS é um modelo híbrido que combina as capacidades adaptativas das redes neurais com a interpretabilidade da lógica fuzzy. Ele tem sido amplamente utilizado para previsão de séries temporais devido à sua capacidade de modelar relações complexas e não lineares nos dados. O modelo ANFIS consiste em uma série de nós interconectados organizados em camadas. (FATEMI; PARVINI, 2022).

3.2.7 Conjunto de dados e configuração experimental

O conjunto de dados contém registros de 1º de janeiro de 2020 a 10 de outubro de 2023 (disponível em: <<https://dados.ons.org.br/dataset/carga-energia>>). As previsões feitas neste trabalho são de um passo à frente, com um horizonte de previsão diário. Isso significa que cada análise é realizada para prever a geração térmica do dia seguinte. Considerando os dados originais da série temporal, o pré-processamento é aplicado para a remoção de ruído do sinal com filtros explicados na seção 3.2.3. Depois disso, os dados são divididos considerando a primeira janela de dados registrados para treinamento e a última parte para teste do modelo.

Nos filtros analisados, o parâmetro p controla a intensidade da atenuação do sinal. Esse parâmetro depende do tipo de filtro. Para o filtro de Hodrick-Prescott, p é o parâmetro de suavização; para o filtro de Christiano-Fitzgerald, p é o período máximo de oscilações; e para a decomposição de tendência sazonal usando o filtro LOESS, p é o comprimento do suavizador de tendência. Esses filtros são baseados nos filtros de séries temporais da biblioteca `statsmodels` (disponível em: <<https://www.statsmodels.org/stable/tsa.html>>).

Para comparação, o LSTM utilizou uma camada oculta, com um limiar de gradiente igual a um, uma taxa de aprendizado igual a 0,005 e 10 unidades ocultas. Para o ANFIS, considerou-se um tamanho de passo inicial igual a 0,01, uma taxa de redução do tamanho do passo igual a 0,9 e uma taxa de aumento do tamanho do passo igual a 1,1.

Os cálculos foram realizados utilizando um processador Intel(R) Core(TM) i5-7300HQ com 20,0 GB de memória RAM. O algoritmo foi escrito e executado no Matlab versão R2019a.

3.2.8 Índices de avaliação

Para a avaliação do modelo proposto, foram avaliados o RMSE, o MAE, o erro percentual absoluto médio (MAPE) e o coeficiente de determinação (R^2). (STEFENON *et al.*, 2025), dado por:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (22)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (23)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (24)$$

onde y é o valor observado, \hat{y} é o valor previsto e n é o número de amostras. (RIBEIRO *et al.*, 2023).

3.2.9 Resultados

Nesta seção, os resultados são apresentados. Primeiramente, o GMDH é avaliado e ajustado com base nos resultados obtidos pela configuração de seus hiperparâmetros e estrutura. Em seguida, o método híbrido é avaliado com a aplicação do filtro. Por fim, uma comparação final é apresentada. Na Tabela 1, é apresentada uma avaliação da divisão dos dados, onde a porcentagem de dados de treinamento e teste utilizados é avaliada.

Tabela 9 – Resultados da variação na porcentagem de dados para treinamento e testes.

Treinamento_Teste (%)	Tempo (s)	RMSE	MAE	MAPE	R^2
90_10	0.663	1.06×10^3	4.21	7.83×10^{-1}	0.3868
80_20	0.249	1.12×10^3	3.85×10^1	5.70×10^{-1}	0.5271
75_25	0.218	1.08×10^3	5.25×10^1	2.05×10^{-1}	0.5538
50_50	0.184	1.13×10^3	3.95×10^1	6.14×10^{-1}	0.5532
25_75	0.216	1.13×10^3	3.30	8.77×10^{-1}	0.5014
20_80	0.202	1.13×10^3	8.76×10^1	1.81	0.4937
10_90	0.235	1.12×10^3	4.78×10^1	6.01×10^{-1}	0.5227

O melhor coeficiente de determinação, MAPE, e o segundo melhor RMSE foram obtidos utilizando 75% dos dados para treinamento e 25% para teste. Essa divisão de dados é considerada

Tabela 10 – Variação nos resultados do número de neurônios.

Neurônios.	Tempo (s)	RMSE	MAE	MAPE	R ²
10	0.198	1.09×10^3	5.21×10^1	2.29×10^{-1}	0.5400
20	0.251	1.13×10^3	3.66	8.46×10^{-1}	0.5111
30	0.313	1.16×10^3	1.15×10^2	3.79×10^{-1}	0.4802
40	0.392	1.06×10^3	4.94×10^1	1.95×10^{-1}	0.5703
50	0.516	1.11×10^3	1.43×10^1	9.86×10^{-1}	0.5222
100	0.489	1.17×10^3	1.59×10^2	7.75×10^{-1}	0.4738
200	0.505	1.10×10^3	1.13×10^2	3.66×10^{-1}	0.5356
300	0.527	1.11×10^3	1.60×10^1	9.90×10^{-1}	0.5235
400	0.443	1.14×10^3	2.19×10^1	1.06	0.5030
500	0.496	1.10×10^3	1.31×10^1	9.38×10^{-1}	0.5314

para o restante da avaliação apresentada neste artigo. Os resultados da variação do número de neurônios são apresentados na Tabela. 10.

Na avaliação do número de neurônios utilizados na rede, os menores valores de RMSE e MAPE foram obtidos com 40 neurônios. Considerando esse hiperparâmetro, o modelo alcançou um R² de 0,57, o melhor resultado obtido até o momento nesta avaliação. Em seguida, o número de camadas foi avaliado neste trabalho, e os resultados são apresentados na Tabela11.

Tabela 11 – Resultados para a variação no número de camadas.

Camadas	Tempo (s)	RMSE	MAE	MAPE	R ²
1	0.158	1.23×10^3	1.14×10^1	8.97×10^{-1}	0.4182
2	0.181	1.16×10^3	7.89×10^1	1.89×10^{-1}	0.4852
3	0.466	1.11×10^3	2.11×10^1	6.83×10^{-1}	0.5284
4	0.715	1.10×10^3	3.06×10^1	5.07×10^{-1}	0.5385
5	0.980	1.08×10^3	3.46×10^1	4.85×10^{-1}	0.5493
6	1.118	1.06×10^3	1.14×10^1	8.54×10^{-1}	0.5656
7	1.227	1.09×10^3	9.16	9.07×10^{-1}	0.5455
8	1.519	2.83×10^{12}	1.53×10^{11}	1.22×10^9	-
9	1.626	4.58×10^{15}	2.47×10^{14}	2.57×10^{12}	-
10	1.802	9.11×10^{14}	5.01×10^{13}	5.18×10^{11}	-

Considerando a melhor configuração de parâmetros, o resultado do GMDH é apresentado na Figura 15. Essa comparação mostra que mesmo com um R² inferior a 60%, o método ainda pode apresentar resultados aceitáveis. Na figura 15 devido à alta frequência do sinal, em algumas situações, os valores previstos não correspondem aos valores observados, especialmente quando a variação do sinal é inferior a 1,2. Isso demonstra que quanto maior a variabilidade do sinal, mais difícil é a sua previsão, o que justifica o uso de filtros, conforme discutido na próxima seção.




Figura 15 – Resultados do GMDH de sinais previstos versus observados.
Fonte: Adaptado de (BURATTO *et al.*, 2025)

3.2.10 Método híbrido

O filtro adequado a ser aplicado depende das necessidades de filtragem, considerando a redução de ruído. Se o filtro não for adequado, poderá atenuar o sinal e fazê-lo perder suas propriedades; por outro lado, se for muito superficial, poderá não ser suficiente para realizar a remoção de ruído necessária. Diante desses desafios, três filtros são avaliados neste trabalho: o filtro de Christiano-Fitzgerald, o filtro de Hodrick-Prescott e a decomposição Season-Trend utilizando LOESS.

Tabela 12 – Resultados do HGMDH considerando diferentes filtros.

Filtro	p	Tempo (s)	RMSE	MAE	MAPE	R^2
Christiano-Fitzgerald	9	3.826	9.95	1.19	9.88×10^{-3}	0.9999
	19	1.950	5.98×10^{-1}	1.11×10^{-1}	1.02×10^{-3}	0.9999
	29	2.102	1.15×10^{-1}	2.77×10^{-2}	2.54×10^{-4}	0.9999
	39	1.647	2.24	3.95×10^{-1}	2.89×10^{-3}	1.0000
Hodrick-Prescott	9	1.839	5.71×10^1	3.82	2.99×10^{-2}	0.9965
	19	11.883	2.97×10^1	2.81	2.49×10^{-2}	0.9990
	29	1.872	2.43×10^1	2.34	2.04×10^{-2}	0.9993
	39	1.912	1.77×10^1	7.84×10^{-1}	7.47×10^{-3}	0.9996
Decomposição da tendência sazonal usando LOESS	9	1.917	4.25×10^1	3.45	2.91×10^{-2}	0.9980
	19	2.002	7.82	1.02	8.41×10^{-3}	0.9999
	29	2.101	3.27	2.17×10^{-1}	1.82×10^{-3}	0.9999
	39	2.085	2.06×10^5	1.21×10^4	9.63×10^1	-

O filtro de Christiano Fitzgerald apresentou os melhores resultados em todas as medidas de erro avaliadas para todas as variações de parâmetros consideradas. Considerando que, quanto maior o valor de p , menos características do sinal estão disponíveis, uma vez que a tendência apresenta maior redução de ruído, o menor valor de p foi utilizado para a avaliação do modelo. Os resultados dessa avaliação são apresentados na Figura 116. Considerando essa configuração, a Tabela 13 apresenta os resultados estatísticos para 100 execuções usando inicialização aleatória de pesos.

Os resultados da avaliação estatística comprovam que o método proposto, baseado na etapa de entrada utilizando o filtro de Christiano Fitzgerald, é estável, apresentando uma variân-




Figura 16 – Resultados do HGMDH de sinais previstos versus observados.
Fonte: Adaptado de (BURATTO *et al.*, 2025)

cia do coeficiente de determinação consideravelmente baixa. Todas as medidas avaliadas não apresentaram variação significativa, considerando 100 experimentos. Em especial, o coeficiente de determinação não apresentou variação significativa na avaliação estatística realizada.

Tabela 13 – Avaliação estatística do HGMDH proposto.

Métrica	Min	Max	Média	Mediana	Desvio padrão.	Var.
RMSE	9.07	3.45×10^1	1.25×10^1	1.21×10^1	3.23	1.05×10^1
MAE	1.65×10^{-1}	4.40	1.36	1.28	7.76×10^{-1}	6.02×10^{-1}
MAPE	4.78×10^{-4}	4.12×10^{-2}	1.21×10^{-2}	1.11×10^{-2}	7.25×10^{-3}	5.26×10^{-5}
R^2	9.99×10^{-1}	9.99×10^{-1}	9.99×10^{-1}	9.99×10^{-1}	1.28×10^{-4}	1.63×10^{-8}

3.2.11 Benchmarking

Para a comparação da avaliação, os métodos TFT, TCN e LSTM com os otimizadores SGDM, Adam e RMSprop; o ANFIS com Agrupamento Subtrativo e FCM; e o GMDH padrão são comparados ao HGMDH proposto. Os resultados dessas avaliações são apresentados na Tabela 14. Todos os métodos comparados são avaliados com e sem filtros para demonstrar que, mesmo utilizando filtros, o método proposto supera as demais estruturas.

Comparando diferentes modelos, o ANFIS apresentou resultados promissores quando a etapa de entrada do filtro não foi considerada (utilizando o filtro, o HGMDH obteve melhores resultados), e este modelo obteve o segundo melhor resultado considerando o uso do filtro. Os resultados do LSTM, utilizando todos os otimizadores avaliados, foram piores, apresentando maiores erros e exigindo mais tempo para treinamento e teste do modelo. Os modelos baseados em transformadores (TFT e TCN) apresentaram resultados promissores em relação ao MAPE, porém com RMSE e MAE maiores do que o HGMDH proposto.

De forma geral, o HGMDH proposto apresentou os melhores resultados em todas as métricas avaliadas, demonstrando que essa abordagem é promissora para este problema.

Tabela 14 – Benchmarking com outros métodos.

Modelo	Otimizador / Aproximação	Filtro	Tempo (s)	RMSE	MAE	MAPE
TFT	SGDM	Não	35.07	1.97×10^2	1.97×10^2	1.73×10^{-2}
		Sim	26.31	2.10×10^1	2.10×10^1	1.96×10^{-3}
	Adam	Não	28.05	2.09×10^2	2.09×10^2	1.84×10^{-2}
		Sim	27.39	1.78×10^1	1.78×10^1	1.66×10^{-3}
	RMSprop	Não	26.09	2.15×10^2	2.15×10^2	1.89×10^{-2}
		Sim	27.01	1.77×10^1	1.77×10^1	1.65×10^{-3}
TCN	SGDM	Não	8.07	1.95×10^2	1.95×10^2	1.71×10^{-2}
		Sim	6.95	2.21×10^1	2.21×10^1	2.06×10^{-3}
	Adam	Não	7.29	1.99×10^2	1.99×10^2	1.75×10^{-2}
		Sim	6.99	1.78×10^1	1.78×10^1	1.66×10^{-3}
	RMSprop	Não	7.63	2.04×10^2	2.04×10^2	1.79×10^{-2}
		Sim	7.52	1.65×10^1	1.65×10^1	1.54×10^{-3}
LSTM	SGDM	Não	22.392	1.33×10^6	5.50×10^1	1.48
		Sim	38.359	1.58×10^4	6.83	3.34×10^{-2}
	Adam	Não	23.418	1.19×10^6	4.71×10^1	6.10×10^{-1}
		Sim	22.477	2.09×10^4	2.89×10^1	1.89×10^{-1}
	RMSprop	Não	24.708	8.24×10^5	6.50×10^1	1.32×10^{-1}
		Sim	21.213	3.02×10^4	7.43×10^1	5.59×10^{-1}
ANFIS	Subtractive Clustering	Não	11.709	3.73×10^4	2.63×10^3	1.83×10^1
		Sim	3.600	4.52×10^1	1.21×10^1	1.01×10^{-1}
	FCM	Não	6.688	9.16×10^2	1.81×10^1	4.82×10^{-1}
		Sim	2.978	2.26×10^1	7.08	5.93×10^{-2}
GMDH	Padrão	Não	2.522	1.09×10^3	5.20×10^1	1.26
HGMDH	Híbrido	Sim	2.180	1.18×10^1	1.32	1.25×10^{-2}

3.3 CF-CNN-BILSTM HÍBRIDO HIPERAJUSTADO POR OTIMIZAÇÃO BAYESIANA PARA PREVISÃO DE GERAÇÃO DE ENERGIA TÉRMICA E DESCARBONIZAÇÃO

3.3.1 Introdução

A matriz energética brasileira é caracterizada por uma significativa dependência da energia hidrelétrica (STEFENON *et al.*, 2024a). Essa dependência exige uma estrutura de planejamento sofisticada para gerenciar a variabilidade temporal e espacial dos recursos hídricos de forma eficaz (AQUINO *et al.*, 2025). O sistema elétrico brasileiro emprega uma estrutura de planejamento hierárquico que opera em múltiplos horizontes temporais, cada um abordando objetivos específicos e utilizando modelos computacionais especializados (PEDRINI; BELTRÁN; FINARDI, 2024). O objetivo principal é atender à demanda projetada com custos operacionais mínimos, levando em consideração a natureza estocástica de um sistema de base hidrotérmica (STEFENON *et al.*, 2023).

A produção de energia hidrelétrica está sujeita a variações devido à flutuação do fluxo de água, que pode ser influenciada por mudanças sazonais e condições climáticas (LARCHER *et al.*, 2024). As usinas termelétricas, menos afetadas por essa variabilidade, desempenham um papel vital na compensação de possíveis déficits na geração hidrelétrica. Previsões precisas de geração

de energia permitem que os operadores do sistema equilibrem a rede de forma eficaz, garantindo um fornecimento de energia confiável (RIBEIRO *et al.*, 2024). O custo de geração de eletricidade a partir de fontes térmicas é geralmente maior do que o de fontes hidrelétricas, principalmente devido aos custos com combustível e aos custos ambientais associados (STANEK *et al.*, 2018). Ao prever as necessidades de geração térmica, os operadores podem otimizar o despacho das usinas, priorizando o uso da energia hidrelétrica, mais econômica, quando disponível, e reservando a geração térmica para períodos de maior demanda ou menor disponibilidade hidrelétrica. Essa estratégia minimiza os custos operacionais gerais do sistema (BURATTO *et al.*, 2024b).

A previsão das necessidades de geração térmica auxilia no planejamento das atividades de manutenção tanto para usinas térmicas quanto hidrelétricas. Ao antecipar os períodos em que a geração térmica será essencial, a manutenção pode ser planejada para momentos de menor demanda ou maior disponibilidade hidrelétrica, garantindo que as usinas térmicas estejam operacionais quando mais necessárias. Essa previsão aumenta a confiabilidade e a eficiência do sistema elétrico (BURATTO *et al.*, 2024).

Nos mercados de energia, previsões precisas da capacidade de geração são vitais para a negociação e os acordos contratuais. Compreender quando a geração térmica será necessária permite que os participantes do mercado tomem decisões informadas, protejam-se contra a volatilidade dos preços e gerenciem os riscos associados à escassez ou ao excedente de oferta (HAUGEN *et al.*, 2019).

A redução das emissões de dióxido de carbono (CO) por meio da conversão catalítica com hidrogênio para a produção de metanol a partir de uma usina de ciclo combinado a gás é uma alternativa para converter o CO dos gases de combustão. Este produto é utilizado nas indústrias de plásticos e farmacêutica (AL-ELANJAWY; YILMAZ, 2025). Considerando que a geração térmica está diretamente ligada à descarbonização, este artigo prevê a geração térmica, resultando em uma previsão equivalente de descarbonização.

A geração de eletricidade a partir do carvão tem um impacto potencial no aquecimento global, avaliado em uma análise do ciclo de vida, onde a extração corresponde à maior contribuição estimada em 232 kg de CO₂eq/t de carvão energético. No sistema integrado do Brasil, as usinas termelétricas a carvão respondem por aproximadamente 89,04% da emissão total (NASCIMENTO; SOARES, 2025).

O foco na descarbonização está sendo avaliado em diversos locais, considerando seus efeitos negativos sobre o meio ambiente. Na China, o biochar poderia alcançar emissões negativas de 0,92 bilhão de toneladas, com um custo de comercialização de US\$ 90, considerado o custo líquido médio por tonelada de dióxido de carbono. Isso possibilitaria a neutralidade de carbono em 2060, de acordo com uma análise espacial que avalia os resíduos agrícolas, florestais e de culturas energéticas do país. (DENG *et al.*, 2024).

Com base nessa necessidade, este artigo propõe um modelo híbrido que combina o filtro de caminhada aleatória de Christiano-Fitzgerald (CF) para redução de ruído, redes neurais convolucionais (CNNs) com um modelo de memória de longo prazo bidirecional (BiLSTM)

para previsão, considerando o ajuste fino por meio de uma abordagem de otimização Bayesiana. O ajuste fino dos hiperparâmetros garante que os valores ótimos dos hiperparâmetros sejam utilizados (STEFENON; CRISTOFORETTI; CIMATTI, 2025a).

Embora modelos híbridos de aprendizado profundo que combinam decomposição de sinais, CNNs e arquiteturas recorrentes sejam cada vez mais comuns na literatura de previsão, o diferencial deste trabalho reside em sua integração metodológica. Ao contrário de abordagens anteriores que empregam filtros genéricos ou pré-processamento convencional, o modelo proposto utiliza o filtro CF para separar especificamente os componentes cíclicos, de tendência e irregulares em dados ruidosos de geração térmica. Essa decomposição aprimora a qualidade das entradas antes da extração de características pela CNN e do aprendizado temporal bidirecional pela BiLSTM.

Enquanto outros modelos híbridos frequentemente dependem do ajuste manual ou heurístico de parâmetros, esta estrutura incorpora sistematicamente a otimização Bayesiana para alcançar uma arquitetura altamente otimizada, garantindo assim um desempenho robusto em diferentes horizontes de previsão. Esses elementos, em conjunto, distinguem o pipeline CF-CNN-BiLSTM-Bayesian dos modelos híbridos de previsão existentes, tanto em seu pré-processamento personalizado para dados térmicos quanto em sua estratégia de otimização automatizada e orientada por dados.

A CF-CNN-BiLSTM proposta, hiperajustada pela abordagem de otimização Bayesiana, apresenta as seguintes contribuições:

- Considerando o filtro CF, o modelo CF-CNN-BiLSTM hiperajustado pode ser usado para análise de séries temporais ruidosas.
- O modelo proposto utilizou uma CNN para extrair informações, o que melhora as capacidades de previsão.
- O ajuste fino garante que a melhor configuração de hiperparâmetros seja utilizada, dada uma estrutura otimizada para a previsão.

Além da novidade de combinar o filtro CF, CNN e BiLSTM, o modelo contribui matematicamente de diversas maneiras. O filtro de Christiano-Fitzgerald baseia-se na suposição de passeio aleatório e é formulado como um filtro passa-banda assimétrico ótimo, permitindo a decomposição da série temporal em componentes de tendência e cíclicos por meio de médias móveis ponderadas. Essa base matemática rigorosa garante que a etapa de redução de ruído não seja heurística, mas estatisticamente ótima para processos próximos à raiz unitária.

A arquitetura CNN-BiLSTM é expressa em uma sequência formal de operações de convolução, funções de pooling e equações recorrentes bidirecionais que garantem a extração sistemática de dependências espaciais e temporais. A otimização Bayesiana introduz uma estrutura matemática probabilística, modelando a busca de hiperparâmetros como um processo Gaussiano com funções de aquisição (Melhoria Esperada, Probabilidade de Melhoria ou Limite Superior de

Confiança) que equilibram a exploração e a exploração. Essas formulações matemáticas elevam a abordagem proposta além da hibridização empírica, fornecendo justificativa teórica para o papel de cada componente no aprimoramento da precisão e estabilidade das previsões.

3.3.2 Aplicação do CNN e BiLSTMs

Gong *et al.* (GONG *et al.*, 2025) propuseram um método híbrido chamado TimesNet-BiLSTM paralelo, considerando a STL para filtragem de séries temporais. O TimesNet é um modelo de variação temporal 2D para séries temporais que, em seu artigo, é combinado com o BiLSTM para aprimorar as previsões. Ao aplicar a STL, obtém-se o sinal sem ruído, garantindo que as não linearidades irrelevantes sejam desconsideradas. Para garantir seu melhor uso, os autores aplicaram um ajuste automático. Considerando todas essas modificações, seu modelo superou outras aplicações e motiva nossa proposta de um modelo híbrido CF-CNN-BiLSTM hiperajustado por otimização Bayesiana..

Xiong *et al.* (XIONG *et al.*, 2023) propuseram a hibridização do BiLSTM com a máquina de aprendizagem extrema (ELM). Os pesquisadores consideraram componentes de baixa e alta frequência do parque eólico de Sotavento Galicia, na Espanha. Ao processar dados brutos de energia eólica por meio de zeragem e interpolação da média, eles comprovaram que o ELM e o BiLSTM superaram outros modelos de previsão individuais em termos de precisão.

Liu *et al.* (LIU *et al.*, 2024) estimaram o potencial de geração de eletricidade com base na taxa de separação de resíduos sólidos urbanos até 2035. Os pesquisadores classificaram as correlações dos fatores que influenciam a geração de resíduos por meio da análise de relações cinzentas (GRA) e integraram o modelo BiLSTM para melhorar a precisão da previsão, utilizando três importantes indicadores econômicos, sociais e populacionais como dados de entrada. O modelo híbrido GRA-BiLSTM apresentou melhor desempenho do que os outros sete modelos de aprendizado profundo comparados nos experimentos. A eficiência da geração de eletricidade mostrou uma tendência de alta, passando de 0,316 MWh/ton sem separação completa para 0,807 MWh/ton.

Chen *et al.* (CHEN *et al.*, 2022) propuseram uma abordagem inovadora baseada em aprendizado profundo para modelar o processo de incineração em usinas de valorização energética de resíduos. O trabalho demonstrou que uma arquitetura CNN-BiLSTM é altamente eficaz na extração de características complexas de dados a partir de parâmetros de entrada multidimensionais. Nessa abordagem, o componente BiLSTM aprimorou a precisão da previsão quando combinado com a CNN, permitindo que o modelo aprendesse dependências temporais a partir de dados operacionais históricos. Como resultado, o método proposto contribuiu para melhorias na eficiência econômica, segurança e estabilidade operacional de instalações de valorização energética de resíduos, gerando estimativas mais precisas de vapor de saída e oxigênio nos gases de combustão.

De acordo com Zhu *et al.* (ZHU *et al.*, 2025), Os aquecedores de alta pressão em usinas termelétricas a carvão podem se beneficiar significativamente de técnicas avançadas baseadas

em dados para monitoramento de estado e detecção de anomalias. Em seu estudo, os autores utilizaram dados operacionais históricos para realizar a seleção de características e aplicaram um modelo híbrido CNN-BiLSTM para previsão de estado. Essa abordagem não apenas aprimorou as capacidades de monitoramento, como também alcançou uma alta precisão de previsão de 96,63% durante os testes, permitindo a detecção precisa de anomalias. Além disso, o desempenho preditivo do modelo foi otimizado por meio do ajuste bayesiano de hiperparâmetros, contribuindo para sua robustez e confiabilidade.

Yu *et al.* (YU *et al.*, 2023) propuseram uma estrutura CNN–BiLSTM–Atenção para avaliar emissões de poluentes e eficiência operacional em fornos de leito fluidizado circulante. Com foco nas emissões de SO₂ e NO_x, a abordagem visa reduzir custos operacionais e mitigar poluentes gasosos. O componente CNN é usado para extrair características localizadas e relevantes de dados brutos de séries temporais e filtrar informações irrelevantes. O módulo BiLSTM captura dependências temporais de longo prazo, enquanto o mecanismo de Atenção destaca as informações mais críticas dentro da sequência. Juntos, esses elementos permitem uma previsão mais precisa e um controle aprimorado dos níveis de emissão, fornecendo uma solução robusta para otimizar o desempenho do forno e reduzir os impactos ambientais.

A previsão da posse de veículos com células de combustível permitiu verificar a redução das emissões de carbono através da aplicação da análise de relações cinzentas com BiLSTM na China, avaliando a redução das emissões de gases de efeito estufa em aproximadamente 23,83 Mt CO₂eq até 2035(LIU; ZHENG; LAI, 2024).

O modelo BiLSTM é responsável por avaliar diferentes condições de operação associadas à CNN, aprimorando a capacidade de diferenciação em padrões de falhas(THANH; CHO, 2024). O otimizador baseado em Newton-Raphson, associado à CNN-BiLSTM, em horizontes de 5, 10 e 15 dias, melhorou a precisão na previsão do mercado de bioenergia, proporcionando melhor alocação de capital e reduzindo os impactos ambientais (GUO *et al.*, 2025). A avaliação da correlação espaço-temporal em períodos chuvosos e ensolarados para CNN-BiLSTM com previsão de potência fotovoltaica em curtíssimo prazo apresenta alta precisão (LIU; LIU; LI, 2024).

3.3.3 Metodologia

A previsão da geração de energia térmica é crucial para a gestão eficiente de energia e a estabilidade da rede, bem como para a compreensão das emissões de CO (foco deste artigo). Devido à natureza dinâmica e não linear dos processos de geração de energia, os modelos de aprendizado profundo, especialmente as arquiteturas híbridas, são altamente eficazes para capturar padrões espaciais e temporais em dados de séries temporais (SILVA; FINARDI; STEFENON, 2024). Este artigo propõe uma arquitetura que combina o filtro CF, CNNs e redes BiLSTM, a qual é explicada nesta seção.

Neste estudo, a otimização Bayesiana foi implementada utilizando um processo Gaussiano como modelo substituto, com a função de aquisição de melhoria esperada (EI) guiando a

busca por hiperparâmetros ótimos. O processo de otimização avalia iterativamente configurações candidatas, equilibrando a exploração do espaço de hiperparâmetros com a exploração de regiões promissoras.

3.3.4 Filtro Christiano-Fitzgerald (CF)

O filtro CF é uma técnica amplamente utilizada para remoção de ruído e extração de tendências em séries temporais, particularmente em aplicações econômicas e financeiras (DUTRA; DIAS; TEIXEIRA, 2022). Trata-se de um filtro passa-banda projetado para isolar componentes cíclicos dentro de uma faixa de frequência específica, suprimindo tanto o ruído de alta frequência quanto as tendências de baixa frequência. O filtro CF pressupõe que o sinal subjacente segue um padrão aleatório, permitindo uma ponderação otimizada, baseada em dados, das observações passadas e futuras.

Ao aplicar este filtro, as flutuações de curto prazo são suavizadas sem distorcer a estrutura de longo prazo da série, tornando-o especialmente eficaz para revelar tendências e ciclos latentes em dados de séries temporais ruidosos. Seja $\{x_t\}_{t=1}^T$ uma série temporal univariada de comprimento T . O filtro CF visa extrair componentes cíclicos de $\{x_t\}$ dentro de uma faixa de frequência especificada. $[\omega_1, \omega_2]$, with $0 < \omega_1 < \omega_2 < \pi$. O componente filtrado (cíclico) no instante t é escrito como

$$\hat{c}_t = \sum_{j=-(t-1)}^{T-t} b_{j,t} x_{t+j}, \quad t = 1, \dots, T, \quad (25)$$

onde \hat{c}_t é o componente cíclico estimado de x_t , $b_{j,t}$ são pesos de filtro variáveis no tempo e j indexa adiantamentos ($j > 0$) e atrasos ($j < 0$).

Se a série fosse infinitamente longa e centrada em t , o filtro passa-banda ótimo teria pesos simétricos dados por

$$b_0 = \frac{\omega_2 - \omega_1}{\pi}, \quad (26)$$

$$b_j = \frac{\sin(j\omega_2) - \sin(j\omega_1)}{\pi j}, \quad j \neq 0. \quad (27)$$

Assim, o ciclo é calculado como

$$\hat{c}_t = b_0 x_t + \sum_{j=1}^{\infty} b_j (x_{t+j} + x_{t-j}). \quad (28)$$

onde ω_1 é a frequência de corte inferior, ω_2 é a frequência de corte superior, e os coeficientes $\{b_j\}$ diminuem à medida que j aumenta (BRANCO; CAVALCA; OVEJERO, 2024).

O filtro CF caracteriza-se pela sua otimização para séries que exibem um comportamento de passeio aleatório ou próximo da raiz unitária, e pela sua flexibilidade para realizar filtragem unilateral (em tempo real) e bilateral. O filtro CF é um método poderoso para a remoção de ruído em dados de séries temporais (CHUKWU; VASILEV; SAHA, 2024). Usando

statsmodels.tsa.filters a biblioteca, O filtro CF é ajustado com base em um hiperparâmetro de suavização (λ), conforme apresentado na Figura.17. Valores mais altos de aumentam a suavização da série temporal.

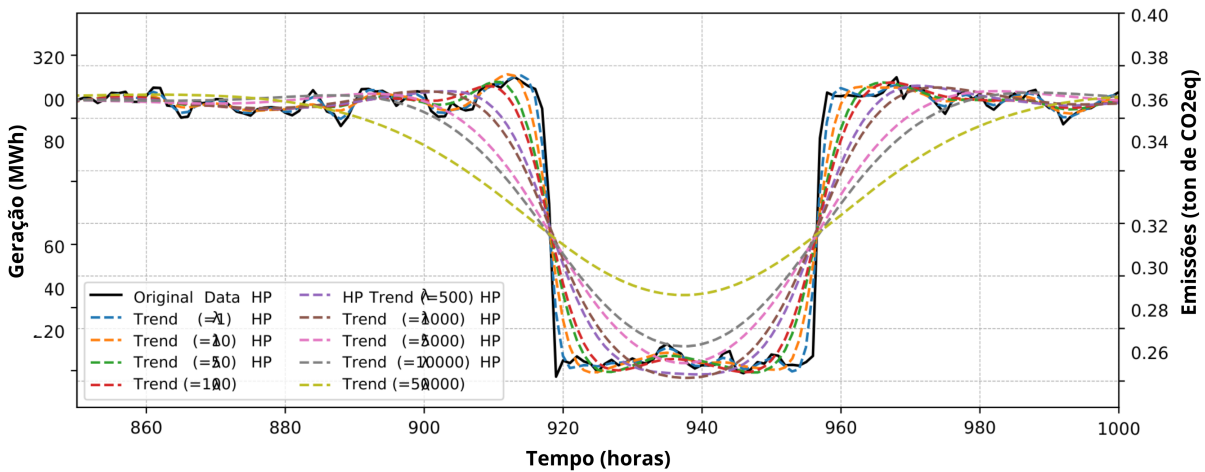


Figura 17 – Tendências do filtro HP em diferentes valores de lambda (Λ).

Fonte: Adaptado de (BURATTO *et al.*, 2025)

3.3.5 CNN-BiLSTM

As CNNs são projetadas para processar dados em formato de grade, como dados sequenciais (SANTOS *et al.*, 2021). As principais características incluem camadas convolucionais para extrair padrões locais, camadas de pooling para redução de dimensionalidade e a captura hierárquica de características, desde abstrações de baixo nível até abstrações de alto nível. Matematicamente, uma operação de convolução é definida como:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau) d\tau, \quad (29)$$

onde f é o sinal de entrada, g é o kernel e t representa a posição. O pooling, geralmente o max pooling, reduz as dimensões do mapa de características (CORSO *et al.*, 2023). Para um mapa de características X com dimensões $h \times w$, o max pooling pode ser expresso como:

$$X_{pooled}(i, j) = \max_{(p, q) \in \text{window}} X(p, q). \quad (30)$$

As redes LSTM superam as limitações das redes neurais recorrentes tradicionais usando portas para controlar o fluxo de informações (KASBURG; STEFENON, 2019). Em uma BiLSTM, as sequências são processadas tanto na direção direta quanto na inversa. A LSTM

direta processa a sequência da seguinte forma:

$$\begin{aligned}
i_t &= \sigma(W_i x_t + U_i h_{t-1} + b_i), \\
f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f), \\
o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o), \\
c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c), \\
h_t &= o_t \odot \tanh(c_t),
\end{aligned} \tag{31}$$

onde i_t , f_t e o_t representam portas de entrada, esquecimento e saída, respectivamente, e \odot denota multiplicação elemento a elemento (STEFENON *et al.*, 2024).

O LSTM reverso segue uma formulação semelhante, mas processa a sequência na ordem inversa. A saída final do BiLSTM combina os estados ocultos de ambas as direções:

$$H_t = [\vec{h}_t; \overleftarrow{h}_t], \tag{32}$$

onde $[\cdot]$ denota concatenação.

A arquitetura CNN-BiLSTM integra esses componentes de forma eficaz. (LU *et al.*, 2021). Primeiro, o módulo CNN extrai características espaciais da entrada, representadas como:

$$X_{CNN} = \text{CNN}(X_{input}). \tag{33}$$

Essa saída é transformada em um formato sequencial adequado para a camada BiLSTM, que a processa para capturar dependências temporais:

$$H_{BiLSTM} = \text{BiLSTM}(X_{CNN}). \tag{34}$$

Finalmente, a saída do módulo BiLSTM é passada por uma camada totalmente conectada para previsão. (STAFFINI, 2023). Para tarefas de classificação com C classes, aplica-se a função de ativação softmax:

$$P(y = c | X) = \frac{\exp(W_c H + b_c)}{\sum_{k=1}^C \exp(W_k H + b_k)}, \tag{35}$$

onde W_c e b_c são os pesos e vieses para a classe c .

Ao combinar o filtro de caminhada aleatória CF para redução de ruído, CNNs para extração de características espaciais e BiLSTMs para modelagem de dependência temporal, a arquitetura CF-CNN-BiLSTM proposta captura efetivamente a dinâmica complexa das séries temporais, fornecendo previsões precisas e confiáveis.

3.3.6 Otimização Bayesiana

A otimização Bayesiana é uma estratégia para otimizar uma função objetivo desconhecida e de avaliação dispendiosa $f : \mathcal{X} \rightarrow \mathbb{R}$, tipicamente definida sobre um domínio limitado $\mathcal{X} \subset \mathbb{R}^d$ (ZULFIQAR *et al.*, 2022). O objetivo é encontrar o minimizador global da função:

$$x^* = \arg \min_{x \in \mathcal{X}} f(x). \quad (36)$$

Como a função é considerada uma caixa preta, nós a modelamos usando um substituto probabilístico. Uma escolha comum é um Processo Gaussiano (GP), que fornece uma distribuição a priori sobre as funções e é totalmente especificado por uma função média $m(x)$ e uma função de covariância $k(x, x')$:

$$f(x) \sim \mathcal{GP}(m(x), k(x, x')). \quad (37)$$

Na maioria dos casos, assume-se que a função média é zero, ou seja, $m(x) = 0$, e a função de covariância é escolhida para codificar as suposições de suavidade. (ZUEGE *et al.*, 2025). Um kernel amplamente utilizado é o exponencial ao quadrado (também conhecido como kernel de função de base radial ou RBF), definido como:

$$k(x, x') = \sigma_f^2 \exp\left(-\frac{\|x - x'\|^2}{2\ell^2}\right), \quad (38)$$

onde σ_f^2 é a variância do sinal e ℓ é o parâmetro de escala de comprimento.

Dado um conjunto de dados de n observações $\mathcal{D}_n = \{(x_i, y_i)\}_{i=1}^n$, onde $y_i = f(x_i) + \varepsilon_i$ e $\varepsilon_i \sim \mathcal{N}(0, \sigma_n^2)$ é o ruído de observação, a posteriori do GP em uma nova entrada x é uma distribuição Gaussiana com média:

$$\mu_n(x) = k(x)^\top [K + \sigma_n^2 I]^{-1} y, \quad (39)$$

e variância:

$$\sigma_n^2(x) = k(x, x) - k(x)^\top [K + \sigma_n^2 I]^{-1} k(x), \quad (40)$$

onde $k(x)$ é o vetor de covariâncias entre x e as entradas observadas, e K é a matriz de covariância sobre as entradas observadas (STEFENON *et al.*, 2024b).

Para decidir onde realizar a próxima avaliação, a Otimização Bayesiana utiliza uma função de aquisição, que quantifica a utilidade da amostragem em qualquer ponto do domínio (VICTORIA; MARAGATHAM, 2021). Uma das funções de aquisição mais populares é a EI, definida como o melhor valor observado $f^+ = \min\{y_1, \dots, y_n\}$ como:

$$\begin{aligned} EI(x) = & (\mu_n(x) - f^+) \cdot \Phi\left(\frac{\mu_n(x) - f^+}{\sigma_n(x)}\right) \\ & + \sigma_n(x) \cdot \phi\left(\frac{\mu_n(x) - f^+}{\sigma_n(x)}\right) \end{aligned} \quad (41)$$

onde Φ e φ denotam a função de distribuição acumulada e a função de densidade de probabilidade da distribuição normal padrão, respectivamente (STEFENON; CRISTOFORETTI; CIMATTI, 2025b).

Outra função de aquisição é a Probabilidade de Melhoria (PI), que mede a probabilidade de que a amostragem em x melhore o melhor resultado atual por pelo menos uma pequena margem $\xi > 0$:

$$PI(x) = \Phi\left(\frac{\mu_n(x) - f^+ - \xi}{\sigma_n(x)}\right). \quad (42)$$

Uma estratégia alternativa é o Limite Superior de Confiança (UCB, na sigla em inglês), que equilibra a exploração e a exploração por meio de um parâmetro ajustável $\lambda > 0$:

$$UCB(x) = \mu_n(x) + \lambda \sigma_n(x). \quad (43)$$

O procedimento de otimização é iterativo. A cada passo, o modelo substituto é atualizado com a observação mais recente e a função de aquisição é maximizada para selecionar o próximo ponto de consulta. Esse processo continua até que um critério de parada seja atingido, como um limite de orçamento ou a convergência do modelo (LINDAUER *et al.*, 2022).

O desempenho do algoritmo pode ser avaliado usando a noção de arrependimento cumulativo, que mede a diferença total entre o ótimo global desconhecido e os valores da função consultados durante a otimização:

$$R_n = \sum_{t=1}^n (f(x^*) - f(x_t)), \quad (44)$$

onde x_t é o ponto avaliado na iteração t , e x^* é o minimizador global da função verdadeira. Sob hipóteses apropriadas, os algoritmos de Otimização Bayesiana podem alcançar um arrependimento sublinear, o que implica convergência para o ótimo global ao longo do tempo (WANG *et al.*, 2023).

3.3.7 Base de dados

A Usina Termoelétrica de Candiota é um complexo energético a carvão localizado em Candiota, Rio Grande do Sul, Brasil, com capacidade instalada total de aproximadamente 796 MW. Desenvolvida em três fases principais, Candiota I (1961), Candiota II, também conhecida como Presidente Médici (1974/1986), e Candiota III (2011), a usina obtém seu carvão de baixo poder calorífico e alto teor de cinzas diretamente da mina de Candiota, adjacente à usina. Após a federalização e décadas sob controle estatal, a usina foi privatizada em 2023 como parte de um movimento mais amplo de descarbonização.

Neste artigo, a usina Candiota III é considerada um estudo de caso. A série temporal de sua geração de energia, refletida por sua emissão de CO₂, é apresentada na Figura 18. Este estudo concentra-se nas emissões de CO₂ para calcular os experimentos.




Figura 18 – Dados originais de séries temporais.
Fonte: Adaptado de (BURATTO *et al.*, 2025)

3.3.8 Configuração do experimento

Os experimentos foram computados no Google Colab usando uma unidade de processamento gráfico NVIDIA T4 de 16 GB e 12 GB de memória RAM. Os algoritmos foram escritos em Python. Para a análise de desempenho, foram considerados o RMSE (Erro Quadrático Médio), o MAPE (Erro Percentual Absoluto Médio) e o MSLE (Erro Logarítmico Quadrático Médio), dados por:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (45)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (46)$$

$$\text{MSLE} = \frac{1}{n} \sum_{i=1}^n (\log(1 + y_i) - \log(1 + \hat{y}_i))^2 \quad (47)$$

onde y_i é o valor real (verdadeiro), \hat{y}_i é o valor previsto e n é o número total de observações.

3.3.9 Análise comparativa

Para comparação, o multi-layer perceptron (MLP) (WANG *et al.*, 2024), codificador denso de séries temporais (TiDE) (NAZIR *et al.*, 2025), interpolação hierárquica neural para séries temporais (NHITS) (STEFENON *et al.*, 2025), análise de expansão de base neural para séries temporais (NBEATS) (ORESHKIN *et al.*, 2021), rede neural recorrente (RNN) (AMALOU; MOUHNI; ABDALI, 2022), dilatada RNN (Dilated RNN) (SMYL; DUDEK; PEŁKA,

2023), LSTM (ABBASIMEHR; PAKI, 2022), unidade recorrente com portão (GRU), modelo autorregressivo profundo (DeepAR), transformador de fusão temporal (TFT) (LIM *et al.*, 2021), informante (ZHOU *et al.*, 2021), transformador de séries temporais baseado em patches (PatchTST) (ZHANG *et al.*, 2024), transformador decomposto com frequência aprimorada (FEDformer) (WANG; ZHU; KANG, 2023), transformador decomposto com frequência aprimorada (TCN) (DUDUKCU *et al.*, 2023), bidirecional TCN (BiTCN) (CHEN *et al.*, 2023), rede de séries temporais (TimesNet) (ZHAO *et al.*, 2024) foram comparados ao método proposto.

3.3.10 Resultados

Na primeira fase da análise, são testadas as combinações de dados utilizadas para treinar o modelo. Isso inclui avaliar o deslizamento de dados, quantas etapas anteriores são necessárias para fazer a previsão, qual o tamanho de lote apropriado para treinar o modelo, qual a influência de uma previsão com variação no horizonte, bem como usar mais dados para treinamento ou teste. Na Tabela 15, a divisão dos dados é avaliada.

Tabela 15 – Análise da divisão dos dados (treino/teste).

Divisão	RMSE	MAPE	MSLE	Tempo (s)
60/40	1.48×10^{-2}	2.41×10^{-2}	1.27×10^{-4}	6.66×10^1
65/35	9.38×10^{-3}	1.37×10^{-2}	5.01×10^{-5}	6.73×10^1
70/30	8.86×10^{-3}	1.29×10^{-2}	4.50×10^{-5}	6.90×10^1
75/25	8.98×10^{-3}	1.53×10^{-2}	4.67×10^{-5}	7.64×10^1
80/20	7.87×10^{-3}	1.06×10^{-2}	3.55×10^{-5}	7.96×10^1
85/15	7.43×10^{-3}	1.24×10^{-2}	3.12×10^{-5}	7.27×10^1
90/10	7.76×10^{-3}	1.09×10^{-2}	3.45×10^{-5}	7.66×10^1

Melhores resultados estão em negrito.

Na Tabela 16, é avaliado o número de passos de tempo anteriores (NPTS).

Tabela 16 – Análise do NPTS usado para previsão.

NPTS	RMSE	MAPE	MSLE	Tempo (s)
10	8.06×10^{-3}	1.26×10^{-2}	3.75×10^{-5}	5.23×10^1
20	7.62×10^{-3}	9.96×10^{-3}	3.36×10^{-5}	5.57×10^1
30	7.55×10^{-3}	9.82×10^{-3}	3.27×10^{-5}	5.25×10^1
40	9.91×10^{-3}	1.37×10^{-2}	5.68×10^{-5}	5.35×10^1
50	8.58×10^{-3}	1.14×10^{-2}	4.24×10^{-5}	5.46×10^1
60	1.25×10^{-2}	1.80×10^{-2}	8.96×10^{-5}	5.78×10^1
70	9.25×10^{-3}	1.56×10^{-2}	4.88×10^{-5}	5.27×10^1
80	7.96×10^{-3}	1.05×10^{-2}	3.62×10^{-5}	5.19×10^1
90	9.68×10^{-3}	1.50×10^{-2}	5.42×10^{-5}	5.86×10^1
100	9.43×10^{-3}	1.43×10^{-2}	5.09×10^{-5}	5.81×10^1

Melhores resultados estão em negrito.

Os melhores resultados em termos de redução de erros foram obtidos com um NPTS de 30, razão pela qual esse valor foi utilizado neste modelo. A Tabela 17 mostra uma análise da

influência da variação do tamanho do lote no desempenho do modelo. Os melhores valores de RMSE e MSLE foram obtidos com um tamanho de lote de 16, e o melhor MAPE foi obtido com um tamanho de lote de 32. Considerando que, com um tamanho de lote igual a 16, houve duas métricas de avaliação de erros superiores, esse valor foi considerado o padrão para análises futuras.

Tabela 17 – Análise do tamanho do lote.

Tamanho do lote	RMSE	MAPE	MSLE	Tempo (s)
2	8.14×10^{-3}	1.14×10^{-2}	3.81×10^{-5}	4.62×10^2
4	8.32×10^{-3}	1.06×10^{-2}	3.99×10^{-5}	2.43×10^2
8	7.79×10^{-3}	1.25×10^{-2}	3.45×10^{-5}	1.27×10^2
16	6.72×10^{-3}	9.89×10^{-3}	2.56×10^{-5}	7.82×10^1
32	7.13×10^{-3}	9.74×10^{-3}	2.94×10^{-5}	5.09×10^1
64	8.91×10^{-3}	1.14×10^{-2}	4.58×10^{-5}	3.25×10^1
128	8.62×10^{-3}	1.36×10^{-2}	4.23×10^{-5}	2.57×10^1
256	8.51×10^{-3}	1.14×10^{-2}	4.15×10^{-5}	1.81×10^1
512	9.89×10^{-3}	1.42×10^{-2}	5.56×10^{-5}	1.53×10^1
1024	1.72×10^{-2}	2.69×10^{-2}	1.70×10^{-4}	1.51×10^1

Melhores resultados estão em negrito.

Em termos de tempo, os valores mais altos de tamanho de lote apresentam menor tempo de processamento em comparação com o uso de valores mais baixos. O tamanho de lote igual a 2 foi a configuração que levou mais tempo de processamento. Considerando que a análise é offline, o tempo de processamento não é uma restrição nesta análise. A seguir, a Tabela 18 mostra uma avaliação do erro de previsão em relação à variação no horizonte de previsão.

Tabela 18 – Análise do horizonte de previsão.

Horizonte	RMSE	MAPE	MSLE	Tempo (s)
6	8.06×10^{-3}	1.12×10^{-2}	3.72×10^{-5}	8.41×10^1
12	8.19×10^{-3}	1.13×10^{-2}	3.86×10^{-5}	9.31×10^1
18	7.65×10^{-3}	1.32×10^{-2}	3.30×10^{-5}	8.00×10^1
24	8.28×10^{-3}	1.16×10^{-2}	3.95×10^{-5}	8.69×10^1
30	8.68×10^{-3}	1.24×10^{-2}	4.35×10^{-5}	8.00×10^1
36	7.31×10^{-3}	1.00×10^{-2}	3.07×10^{-5}	8.70×10^1
42	6.95×10^{-3}	1.07×10^{-2}	2.73×10^{-5}	8.44×10^1
48	7.14×10^{-3}	1.16×10^{-2}	2.87×10^{-5}	8.79×10^1
60	8.64×10^{-3}	1.37×10^{-2}	4.26×10^{-5}	9.75×10^1

Melhores resultados estão em negrito.

Um resultado interessante nesta avaliação foi que o melhor valor de RMSE foi encontrado com o horizonte igual a 42. Normalmente, usar horizontes mais curtos facilita a previsão do modelo, mas, neste caso, houve pouca variação nos resultados devido a essa diferença. Isso demonstra que o modelo pode ser aplicado a qualquer um dos horizontes avaliados.

Um exemplo do resultado da previsão para o sinal original é mostrado na Figura 19, considerando um horizonte de previsão de 60 passos. Esses resultados mostram que o modelo atende satisfatoriamente aos valores de previsão até este ponto, mas quando há grandes variações ou a presença de não linearidades causadas por alta frequência no sinal, a previsão é prejudicada. Para mitigar o efeito dessas não linearidades, um filtro é aplicado para reduzir o ruído no sinal, conforme explicado a seguir.




Figura 19 – Dados originais da série temporal versus sinal previsto.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

3.3.11 Análise de Hiperajuste

O hiperajuste visa definir os melhores (ótimos) valores de hiperparâmetros a serem usados no modelo proposto. Durante o processo de hiperajuste, a otimização Bayesiana testa combinações de valores de hiperparâmetros até encontrar a melhor combinação (com o melhor desempenho), considerando a otimização multiobjetivo. Os resultados dessas tentativas para a função de perda são mostrados na Figura 20.




Figura 20 – Resultados dos testes ao longo das iterações.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

O valor ótimo para os hiperparâmetros foi encontrado após 25 tentativas de combinação. A busca pelos valores ótimos em função da variação dos valores pode ser vista na Figura 21 para o ajuste do LSTM e na Figura 22 para o ajuste da CNN no modelo híbrido CNN-LSTM. Todos esses hiperparâmetros são otimizados iterativamente e combinados para alcançar uma estrutura com hiperparâmetros ótimos, ou seja, um modelo hiperajustado.




Figura 21 – Gráfico de hiperajuste da taxa de aprendizado versus unidades LSTM.

Fonte: Adaptado de (BURATTO *et al.*, 2025)




Figura 22 – Gráfico de hiperajuste do tamanho do kernel versus filtros.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

Considerando o ajuste fino utilizado, o modelo apresentou o melhor desempenho com 221 unidades LSTM, uma taxa de aprendizado de $9,46 \times 10^{-3}$, 27 filtros e um tamanho de kernel igual a 3. Esses valores foram definidos como padrão e utilizados para a análise comparativa final do modelo.

3.3.12 Análise Estatística

Para avaliar a variância do modelo, foram realizadas 50 simulações considerando uma inicialização aleatória. Os resultados estatísticos desta análise, referentes à média, desvio padrão (DP), mínimo (Mín), máximo (Máx), mediana, Q1, Q3, amplitude, intervalo interquartil (IQR), assimetria e curtose, são apresentados na Tabela 19.

O modelo CF-CNN-BiLSTM demonstrou um desempenho sólido em todas as métricas avaliadas, com valores de erro consistentemente baixos. Os erros médios foram pequenos, $5,0789 \times 10^3$, $1,3750 \times 10^2$ e $3,1803 \times 10$, indicando uma saída do modelo geralmente precisa. Os desvios padrão permaneceram baixos, sugerindo um desempenho estável e consistente. A distribuição dos erros apresentou alta assimetria (valores de assimetria: 3,6731, 3,6196 e 6,7099), o que implica uma concentração de erros baixos com alguns outliers mais altos. Isso foi ainda confirmado pelos altos valores de curtose (17,722, 17,342 e 47,483), indicando distribuições com caudas pesadas.

Os valores mínimos estavam próximos de zero, enquanto os valores máximos revelaram a presença de alguns erros relativamente grandes. Apesar disso, os intervalos interquartis foram

Tabela 19 – Resultados estatísticos da CF-CNN-BiLSTM hiperajustada com atenção em 50 execuções.

Estatística	RMSE	MAPE	MSLE
Mean	5.08×10^{-3}	1.37×10^{-2}	3.18×10^{-5}
Std	5.70×10^{-3}	1.58×10^{-2}	1.08×10^{-4}
Min	4.16×10^{-4}	7.24×10^{-4}	9.63×10^{-8}
Max	4.05×10^{-2}	1.11×10^{-1}	9.09×10^{-4}
Median	3.41×10^{-3}	9.12×10^{-3}	6.25×10^{-6}
Q_1 (25%)	1.65×10^{-3}	4.39×10^{-3}	1.47×10^{-6}
Q_3 (75%)	6.16×10^{-3}	1.68×10^{-2}	2.06×10^{-5}
Range	4.01×10^{-2}	1.11×10^{-1}	9.09×10^{-4}
IQR	4.52×10^{-3}	1.25×10^{-2}	1.91×10^{-5}
Skewness	3.67	3.62	6.71
Kurtosis	1.77×10^1	1.73×10^1	4.75×10^1

estreitos e as medianas foram substancialmente menores que as médias, reforçando o forte desempenho típico do modelo. No geral, embora o modelo mostre excelente precisão na maioria dos casos, a presença de outliers raros, porém significativos, especialmente para RMSE e MAPE (ver Figura 23), deve ser considerada em aplicações subsequentes.




Figura 23 – Resultados com valores discrepantes considerando 50 execuções.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

3.3.13 Benchmarking

Para realizar a análise comparativa, diversos modelos consagrados (MLP, TiDE, NHITS, NBEATS, RNN, Dilated RNN, LSTM, GRU, DeepAR, TFT, PatchTST, FEDformer, TCN, BiTCN, TimesNet) foram analisados em diferentes horizontes de avaliação. A Tabela 20 apresenta a análise comparativa para o horizonte de 6 horas.

Nesta análise, alguns modelos não se mostraram promissores para a tarefa em questão. Por exemplo, o modelo TiDE apresentou um MAPE de 32,5%, valor superior ao esperado para a previsão em questão (acima de US\$ 20%). No entanto, alguns modelos se mostraram promissores, como o NBEATS e o PatchTST, que apresentaram um MAPE inferior a 0,6%. Nosso

Tabela 20 – Análise comparativa de modelos para um horizonte temporal de 6 horas..

Modelo	RMSE	MAPE	MSLE	Tempo (s)
MLP	2.83×10^{-2}	7.03×10^{-2}	4.19×10^{-4}	2.29×10^1
TiDE	2.75×10^{-1}	3.25×10^{-1}	4.48×10^{-4}	2.11
NHITS	2.19×10^{-3}	5.33×10^{-3}	2.55×10^{-6}	2.75
NBEATS	2.14×10^{-3}	4.99×10^{-3}	2.45×10^{-6}	2.52
RNN	3.58×10^{-3}	8.33×10^{-3}	6.85×10^{-6}	3.97
Dilated RNN	3.42×10^{-3}	8.53×10^{-3}	6.25×10^{-6}	4.26
LSTM	3.27×10^{-3}	7.99×10^{-3}	5.71×10^{-6}	2.21
GRU	3.55×10^{-3}	8.82×10^{-3}	6.72×10^{-6}	2.06
DeepAR	5.62×10^{-2}	1.37×10^{-1}	1.61×10^{-3}	3.49
TFT	2.59×10^{-3}	6.29×10^{-3}	3.58×10^{-6}	1.15×10^1
Informer	2.83×10^{-2}	6.11×10^{-2}	4.15×10^{-4}	6.83
PatchTST	1.90×10^{-3}	4.73×10^{-3}	1.94×10^{-6}	3.71
FEDformer	9.27×10^{-2}	2.28×10^{-1}	4.99×10^{-3}	7.36
TCN	4.45×10^{-3}	1.08×10^{-2}	1.06×10^{-5}	2.61
BiTCN	8.39×10^{-3}	2.16×10^{-2}	3.78×10^{-5}	2.22
TimesNet	2.40×10^{-3}	5.89×10^{-3}	3.07×10^{-6}	1.12×10^1
Hypertuned CF-CNN-BiLSTM with Attention (Nosso)	1.42×10^{-3}	2.07×10^{-3}	1.11×10^{-6}	9.76×10^1

Melhores resultados estão em negrito

modelo (CF-CNN-BiLSTM hiperajustado com Atenção) superou todos os demais modelos nesta avaliação.

Em relação ao tempo necessário para computar o experimento, nosso modelo levou mais tempo do que todos os modelos comparados, sendo inferior a 100 segundos, o que é aceitável considerando uma análise offline. Uma comparação do sinal previsto versus a série temporal original é apresentada na Figura 24.




Figura 24 – Remoção de ruído de dados de séries temporais versus sinal previsto.

Fonte: Adaptado de (BURATTO *et al.*, 2025)

As implicações práticas das descobertas são particularmente relevantes para operadores de energia e formuladores de políticas. Ao demonstrar que a CF-CNN-BiLSTM hiperajustada com otimização Bayesiana alcança precisão de previsão superior, o estudo fornece uma estrutura

que pode ser aplicada diretamente para otimizar as decisões de despacho em usinas termelétricas, reduzindo custos operacionais e melhorando a estabilidade da rede. É importante ressaltar que a dependência do modelo em dados históricos de geração filtrados, em vez de extensas entradas exógenas, o torna adequado para áreas com instrumentação precária, onde o acesso a dados meteorológicos, de mercado ou baseados em sensores pode ser limitado.

Nesses contextos, o filtro CF aprimora a usabilidade das séries temporais ruidosas disponíveis, enquanto a arquitetura híbrida garante a captura eficaz tanto das flutuações de curto prazo quanto da dinâmica de longo prazo. Isso significa que os operadores de sistemas em ambientes com escassez de dados ainda podem se beneficiar de previsões confiáveis para programar manutenções, planejar a capacidade de reserva e minimizar as emissões de carbono. Além das operações, a metodologia também apoia a tomada de decisões estratégicas, uma vez que previsões precisas de equivalência à descarbonização podem orientar o cumprimento das metas de emissão e o investimento em tecnologias de geração mais limpas.

3.3.14 Limitações

Apesar dos resultados promissores, este estudo apresenta limitações que devem ser reconhecidas. Embora a otimização Bayesiana aprimore a robustez da seleção de hiperparâmetros, o custo computacional do ajuste fino permanece relativamente alto, restringindo sua aplicabilidade em ambientes de tempo real ou com recursos limitados. O desempenho do modelo foi otimizado para horizontes de previsão específicos, e os resultados indicam que o ajuste fino pode não ser efetivamente transferido para outros horizontes sem um novo treinamento. Fatores externos como flutuações nos preços dos combustíveis, variabilidade climática e intervenções políticas não foram incorporados, o que pode influenciar a precisão das previsões em aplicações práticas. Abordar essas limitações em trabalhos futuros, ampliando a validação para diversos conjuntos de dados, integrando variáveis exógenas e explorando outras estratégias de otimização, fortalecerá a confiabilidade e a aplicabilidade da abordagem proposta.

3.4 DESCARBONIZAÇÃO EM USINAS TERMOELÉTRICAS POR ALGORITMOS PARA PREVISÃO DE CARGA

Realizar a previsão de carga em Usinas termoelétricas pode potencializar o maior lucro das operações em conjunto com a descarbonização a partir do algoritmo que com as previsões possuindo um erro extremamente baixo pois colaboram com investidores, reduzindo desse modo a margem pois pode ser criado um green bond token permitindo se houver a divulgação de maior liquidez do ativo e elevar o preço do crédito de carbono se o projeto de usina possibilitar um medidor em tempo real (dMRV), como o BiLSTM prevê picos de demanda e preços horários dentro do sistema da ONS reduz o erro de injeção de carga e multa por sub-geração ou sobre-geração no sistema elétrico e aumenta a margem operacional ao despachar nos horários de preços

de liquidação de diferenças (PLD) mais alto dentro das operações anuais da Usina termoelétricas de biomassa.

O modelo de IA permite modificar de contrato fixo para arbitragem spot elevando as vantagens econômicas da Usina, podendo os investidores receberem os dividendos do token de acordo com o sensor de IoT confirmar o registro do MWh gerado. A margem de erro das previsões de carga e despacho elétrico pode alcançar valores menores que 5% em comparação com outras ferramentas estatísticas e ainda ser reduzido este valor com sensores de IoT que possuem altos níveis de precisão associados aos modelos híbridos aplicados nesta tese.

3.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste estudo, demonstramos que a combinação do filtro CF com uma arquitetura de previsão CNN-BiLSTM e o ajuste automático de hiperparâmetros por meio de otimização Bayesiana produzem resultados promissores para a previsão da geração de energia térmica. Ao decompor os dados brutos de geração em suas componentes de tendência, cíclicas e irregulares, o filtro CF atenua o ruído de forma eficaz e destaca a dinâmica subjacente real. A alimentação desses sinais mais limpos em um modelo CNN-BiLSTM permite a extração de características espaciais e o aprendizado temporal bidirecional, garantindo que tanto flutuações rápidas quanto padrões de longo prazo sejam capturados com alta fidelidade.

Nossos resultados experimentais em conjuntos de dados reais de geração térmica mostram que a abordagem CF-CNN-BiLSTM hiperajustada supera consistentemente os principais métodos de referência em termos de métricas de erro. A integração de uma abordagem de otimização Bayesiana para o hiperajuste refina ainda mais o desempenho do modelo sem tentativas e erros manuais, aumentando a robustez em diversos regimes operacionais. Ao traduzir previsões precisas de geração em um equivalente de descarbonização, quantificando as emissões evitadas associadas ao planejamento da produção térmica, nossa estrutura não apenas apoia a redução de custos operacionais e a estabilidade da rede, mas também contribui diretamente para os objetivos de monitoramento de emissões. Esse foco duplo ressalta a relevância do modelo na transição energética em curso, onde a previsão precisa de fontes de energia tradicionais complementa a integração de energias renováveis e a busca por metas de emissões líquidas zero. A convergência para a configuração ideal foi alcançada após 25 iterações, com a configuração final incluindo 221 unidades LSTM, 27 filtros convolucionais, um tamanho de kernel de 3 e uma taxa de aprendizado de 0,00946. Embora a otimização tenha introduzido sobrecarga computacional adicional, o processo permaneceu viável no treinamento offline, exigindo menos de duas horas no total e melhorando significativamente a precisão preditiva em comparação com o ajuste heurístico.

4 OTIMIZAÇÃO PARA DESCARBONIZAÇÃO EM USINAS TERMOELÉTRICAS DE BIOMASSA CONTRA ATAQUES CIBERNÉTICOS E DESENVOLVIMENTO DE ESTRUTURA METODOLÓGICA PARA ELEVAR O ALCANCE DOS CRÉDITOS DE CARBONO A PARTIR DE BIOCARVÃO

4.0.1 Introdução sobre otimização para descarbonização

A previsão de ataques cibernéticos em modelagem computacional pode ser dividida em duas características principais: aquisição de dados e percepção de estado. A proteção dinâmica da rede está relacionada a módulos de monitoramento de tráfego, que indicam nós e categorias de ataque. Isso permite o desenvolvimento de uma estratégia adequada, a ser executada de acordo com a topologia da rede(LIN *et al.*, 2024). As fases de defesa de segurança são divididas em pré-ataque, durante o ataque e pós-ataque. Consequentemente, esses ataques exigem detecção de intrusão, tecnologia de identificação, calibração de controle e estratégia defensiva para reduzir o impacto econômico e de escala no sistema de energia(YANG; LIU; LI, 2022).

A remediação automatizada, a mitigação a partir da modelagem de ameaças e a segmentação de redes são estratégias para aplicar aprendizado por reforço, selecionando estratégias defensivas como redes Bayesianas, utilizando a documentação de incidentes de segurança passados com o registro de novos padrões de ameaças (KAUR; GABRIJELČIĆ; KLOBUČAR, 2023).

Métodos de armazenamento de segurança de dados usando texto criptografado ou "ciphertext" são outra ferramenta para garantir a segurança dos nós de borda e da consulta de dados, aplicando teoria dos jogos, algoritmo Kademia e criptografia homomórfica, conforme avaliado por (ZHONG; XIONG, 2021).

Os objetivos maliciosos dos ciberataques são danos físicos a componentes, usuários e operadores, causados por vulnerabilidades de segurança em dispositivos eletrônicos de rede que permitem acesso não autorizado a painéis de controle de máquinas(CANONICO; SPERLÌ, 2023).

Os métodos de inteligência artificial (IA) são avaliados como ferramentas que demonstram robustez a valores discrepantes, como o XGBoost e a predição conformal (ZUEGE *et al.*, 2025), autoencoders com memória de longo prazo (LSTM) (GUERRA *et al.*, 2025), e modelos de Floresta Aleatória (TULESKI *et al.*, 2024). Eles apresentam desempenho de detecção superior em comparação com algoritmos de aprendizado profundo empilhados(SEMAN *et al.*, 2025), embora estes pudessem alcançar um melhor desempenho ao usar conjuntos de dados maiores(WANG *et al.*, 2022), onde as redes neurais gráficas podem ser promissoras(YAMAGUCHI *et al.*, 2025).

A tolerância a ataques, mesmo com perdas de desempenho em modelos de aprendizado de máquina que detectam ciberataques existentes no sistema, é o foco da pesquisa científica. No entanto, representa um desafio para os pesquisadores, visto que as medidas preventivas atuais se concentram apenas na detecção de ataques. Alguns pesquisadores estudam o isolamento e

a localização de ataques, e a tolerância é essencial para garantir o funcionamento normal sem afetar a precisão da detecção (DU *et al.*, 2022).

A aplicação de modelos de eventos adequados é fundamental para a resiliência do sistema de energia. Isso é possível quando a compreensão das técnicas em diferentes estágios de eventos extremos e a avaliação de objetivos analíticos são integradas para alcançar a seleção e o projeto de previsões mais precisas para ataques cibernéticos (ZHANG *et al.*, 2022a).

Resiliência é definida como o desempenho do sistema de comunicação e rede, desde o controlador até o sistema de energia, em relação à vulnerabilidade, robustez e recuperação quando ocorrem ataques cibernéticos (GHANBARI-GHALEHJOUGH; TAGHIZAD-TAVANA; NOJAVAN, 2023).

A quantificação da resiliência pós-ataque pode ser estabelecida por meio de três métricas: o número ponderado de eventos extremos, uma perspectiva prospectiva que prevê o pior cenário para a primeira métrica e uma avaliação detalhada da resiliência em cada linha, que pode ser apresentada de forma sobrecarregada devido à projeção do pior cenário (LEI *et al.*, 2022).

Os métodos de resiliência pré e pós-ataque devem combinar nós de comunicação específicos com monitoramento e integração de firewall, evitando a propagação do malware e minimizando os danos (ZHAO *et al.*, 2024).

A interferência de ataques de negação de serviço (DoS) impacta significativamente o processo de tomada de decisões em sistemas de energia, podendo escalar para interrupções no fornecimento de energia e comprometer a estabilidade e a segurança do sistema elétrico (LI; ZHANG; LI, 2025).

A neutralidade de carbono depende de dispositivos eletrônicos de potência e de sua controlabilidade e observabilidade nos dados de comunicação e comando para reduzir a vulnerabilidade a ataques cibernéticos que possam afetar a integridade dos dados (ataques de injeção de dados falsos), a disponibilidade (ataques de negação de serviço) e a confidencialidade (malware) (HOU *et al.*, 2024).

Desenvolver lógica de ação de dispositivos para mitigar ataques maliciosos e coordenar recursos no lado da carga, programando a rede de barramento de comunicação e indicando possíveis cenários de falhas diretas e indiretas, contribui para estabelecer uma estratégia de otimização da resiliência em sistemas de energia (JING *et al.*, 2024).

O ataque de injeção de dados falsos (FDI) pode assumir diferentes formas, como função rampa, injeção de polarização e intervalos de pulso, além de escalar parâmetros e ajustar os limites dos sinais de medição e controle de saída (ABDELKADER *et al.*, 2024).

Existem algumas ferramentas que ajudam a melhorar a resiliência, como gerenciamento de eventos, avaliação de vulnerabilidades para identificar possíveis simulações de ataques e ferramentas de detecção de anomalias para monitorar o tráfego de rede e as possibilidades de acesso ao sistema de controle (REKERHAHO *et al.*, 2024).

Para avaliar a resiliência do sistema elétrico, é necessário verificar os indicadores de avaliação da usina, simular cenários de falhas, estimar o tempo estatístico dos ataques cibernéticos,

estabelecer modos de recuperação e estimar os riscos probabilísticos de frequência e duração das interrupções (YANG *et al.*, 2022).

Em uma usina de energia, é fundamental desenvolver planos de resposta a incidentes para implementar estratégias predefinidas e responder a incidentes de segurança cibernética, minimizando a perda de dados e restaurando informações críticas durante ataques extremos, com planos de backup e recuperação de desastres(LEDMAOUI *et al.*, 2025).

Aplicar métodos de aprendizado profundo para desenvolver um sistema de rastreamento em tempo real e detecção inteligente de ataques cibernéticos, capturando a correlação temporal e com a capacidade de diferenciar medições maliciosas de configurações normais usando um algoritmo de classificação (MOHAMMADPOURFARD *et al.*, 2022).

Desenvolver uma hierarquia de resiliência baseada na classificação da importância da infraestrutura e dos dispositivos responsáveis por proporcionar uma melhor captura de carbono, bem como suas dificuldades de reparo, visto que a estimativa da probabilidade de vulnerabilidade é uma excelente estratégia para ferramentas de IA(MISHRA; KWASNIK; ANDERSON, 2023).

Os possíveis ataques cibernéticos que poderiam afetar cada dispositivo do sistema de pirólise foram avaliados no fluxograma mostrado na Figura 25, que se divide em diferentes categorias de ataque, como FID, MITM, DoS/DDoS e XSS.

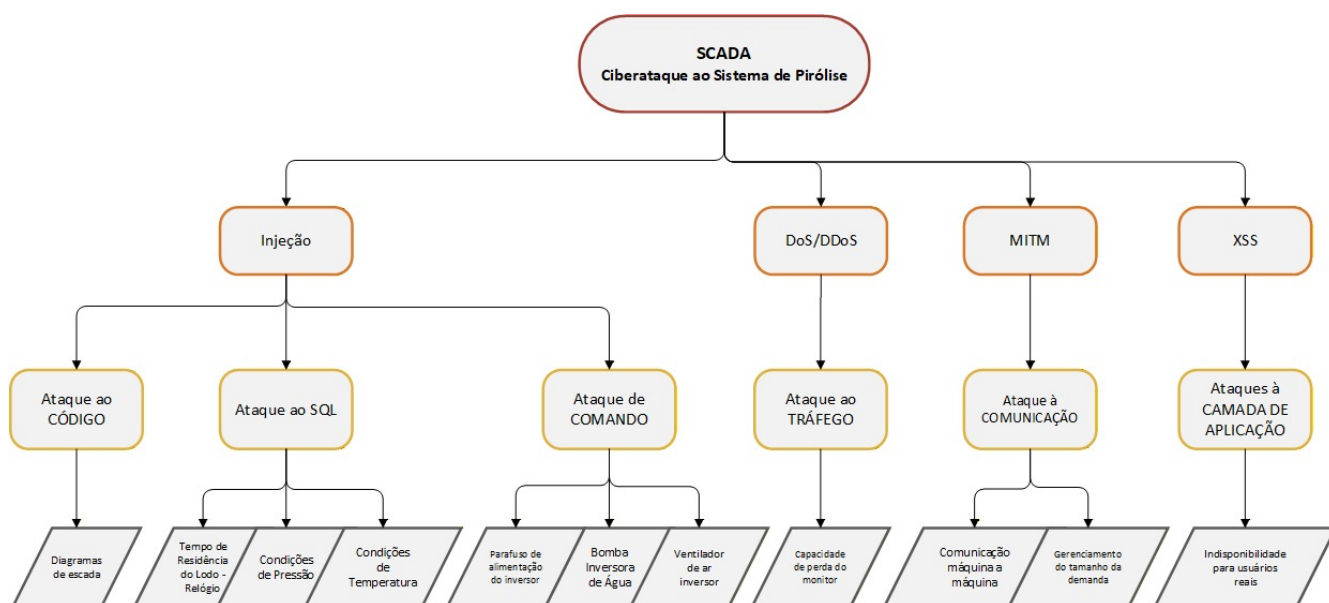


Figura 25 – Fluxograma de possíveis ataques cibernéticos em um sistema de pirólise.

Fonte: Adaptado de (ALANAZI; MAHMOOD; CHOWDHURY, 2023)(TATIPATRI; ARUN, 2024)(OYUCU *et al.*, 2023)

4.0.2 Metodologia do sistema de otimização

O controle do banco de dados criado pelo segmento de ajuste do ponto de ajuste relacionado à temperatura e ao padrão do biochar de lodo seleciona a melhor estrutura de dados no CLP.

Avaliar as características do biocarvão para estimar a rota de captura de carbono, introduzindo-o no solo, seu descarte e o volume em toneladas de dióxido de carbono que pode ser reduzido e para obter créditos de carbono.

Em uma planta de pirólise, é possível selecionar padrões de temperatura para produzir diferentes porosidades e grupos funcionais de biochar em uma rotina de controle.

Diferentes características determinam o potencial de captura de carbono do biochar, como teor de carbono, área superficial, porosidade, grupos funcionais e distribuição do tamanho dos poros (KWON; LEE, 2025).

O monitoramento das propriedades para armazenar um extenso banco de dados a partir de análises contribui para a modelagem e previsão das propriedades da biomassa, apoiando pesquisas em bioenergia e ciência dos materiais, além de avaliar os riscos ambientais durante a produção de biochar(SYGUŁA; ŁYCZKO; BIAŁOWIEC, 2025)

É necessário desenvolver estratégias inovadoras para a remoção eficiente de umidade e poluentes em diferentes tipos de biochar, como na pirólise de lodo de esgoto. A otimização do processo com fluxos de resíduos para recuperação de recursos e desenvolvimento de catalisadores deve levar em consideração a escalabilidade, bem como as preocupações com segurança e meio ambiente(RIJO *et al.*, 2024).

Partículas esféricas significativas e poros abertos são produzidos na usina de pirólise lenta, operando a uma temperatura de 900 °C com lodo de esgoto, apresentando uma estrutura altamente porosa e indicando adsorção de carbono a longo prazo(VALI *et al.*, 2025).

A infraestrutura computacional avançada, aplicando métodos de IA, tem o potencial de revolucionar as estratégias de mitigação e detecção de anomalias com controladores automáticos que mapeiam categorias de distúrbios, especialmente em ataques de atraso e negação de serviço (DoS) na estabilidade do sistema de energia (SEMERTZIS *et al.*, 2024).

A estrutura porosa aumenta a imobilização de metais pesados, com a alta área superficial adsorvendo contaminantes, utilizando o biochar como reservatório de carbono (SHARMA; GHODKE; CHEN, 2024).

O lodo de esgoto tratado por pirólise a temperaturas mais elevadas, gerando carvão vegetal, produz menos componentes voláteis e apresenta maior estabilidade térmica, aumento no volume de poros e na área superficial específica, além de uma diminuição no diâmetro médio dos poros(DENG *et al.*, 2025).

O melhor desempenho ambiental foi obtido pela pirólise de lodo de esgoto, avaliando nove tecnologias de tratamento de acordo com Ren *et al* (REN *et al.*, 2025), devido à tecnologia de aplicação de biocarvão no solo em um modelo de avaliação do ciclo de vida e monetização na China.

A transformação do nitrogênio no tratamento termoquímico e sua participação na formação de carvão, óleo e gás derivados da tecnologia de pirólise podem ser avaliadas para reduzir os precursores de NOx no gás de síntese produzido, facilitar a conversão desses precursores em nitrogênio não poluente ou imobilizar o nitrogênio no biochar o máximo possível(LI *et al.*,

2023a).

Testar diferentes proporções de mistura de resíduos em uma pirólise em pequena escala de lodo de esgoto com resíduos florestais e agrícolas para obter informações sobre a imobilização de metais pesados e a recuperação de nutrientes com biochar a partir desses bio-produtos, maximizando a eficiência de recursos, apoiando a produção de energia e a redução de resíduos(GUSIATIN, 2024).

Os processos físicos integrados com computação avançada contribuem para a gestão de energia e otimização de recursos, oferecendo capacidades de automação a partir de decisões inteligentes, reduzindo ineficiências operacionais e a pegada de carbono(JELINEK *et al.*, 2024).

A segmentação de rede limita as ameaças potenciais, isolando a intrusão e impedindo o movimento lateral, reforçando a resiliência ao adicionar uma camada de defesa e contribuindo para a fácil restauração das operações em caso de um ataque cibernético(CALI; CATAK; HALDEN, 2024).

4.0.3 Resultados avaliados em Usina de Pirólise de lodo

Uma atmosfera dentro do reator de pirólise com controle de temperatura, aplicando o mecanismo de IA, tem a capacidade de aumentar a área superficial e o teor de carbono, contribuindo com a captura direta de dióxido de carbono do ar a partir do biochar ou com o armazenamento de carbono derivado do descarte do solo.

As condições de temperatura são vitais para criar uma atmosfera propícia dentro do reator de pirólise, a fim de obter biochar com maior capacidade de absorção de dióxido de carbono. Um fluxograma avaliando diferentes temperaturas é apresentado na Figura 26, Foi desenvolvido para determinar as condições controladas mais adequadas para o processo de pirólise com melhores características de adsorção.

A pirólise lenta de lodo de esgoto municipal, digerido e não digerido, apresenta diferentes condições de temperatura para a obtenção de biochar com maior capacidade de captura e adsorção de carbono, que depende principalmente da maior área superficial e teor de carbono, com menor relação H/C (VALI *et al.*, 2025).

Relações H/C mais baixas refletem maior estabilidade da adsorção de carbono, promovendo adsorção a longo prazo no solo, sendo 0,4 um excelente valor de referência. A temperatura adequada deve ser avaliada para produzir um biochar com maior área superficial e menor relação H/C (COSTA *et al.*, 2025).

A dosagem do ativador químico tem potencial para aumentar consideravelmente a adsorção de captura de carbono com biochar de lodo. No entanto, é necessário avaliar a redução do volume do composto químico para minimizar a corrosão do equipamento e a poluição ambiental, além de aumentar a adsorção de dióxido de carbono(WU *et al.*, 2025).

O biocarvão de lodo de esgoto, preparado a uma temperatura de 600 °C em um reator de pirólise com NaOH como ativador, atingiu 1,17 mmol/g de captura direta de dióxido de carbono do ar, com uma adsorção mínima de 0,42 mmol/g, e uma concentração de carga de 20%,

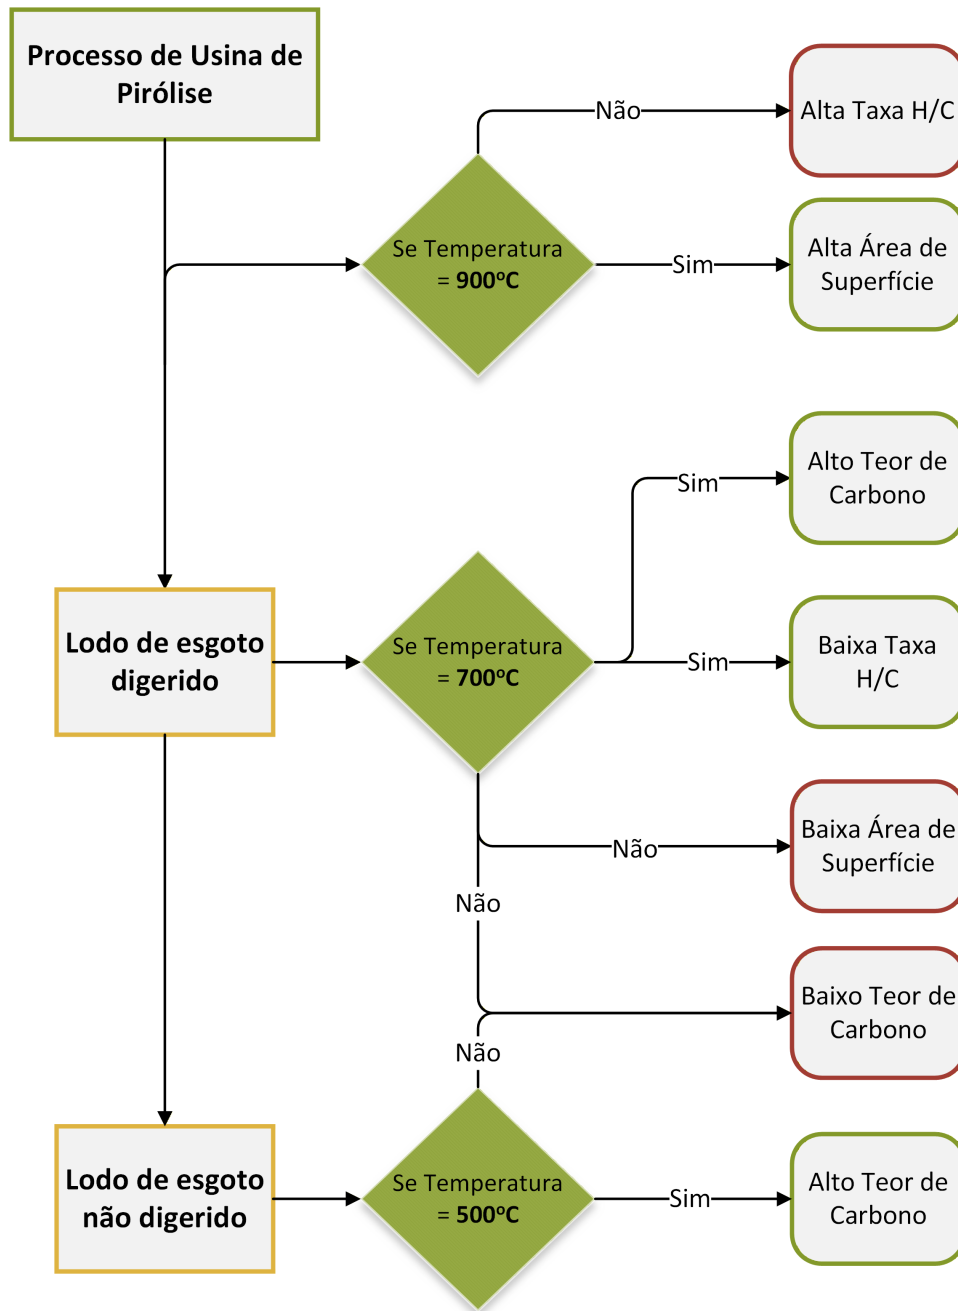


Figura 26 – Fluxograma das condições de temperatura para otimização da adsorção de biochar na adsorção de carbono.

Fonte: Adaptado de (VALI *et al.*, 2025)(OKTAVIANA *et al.*, 2025)(ŘIMNÁČOVÁ *et al.*, 2024)(CHAGAS *et al.*, 2024).

apresentando porosidade e volume elevados(LIU *et al.*, 2024).

A dependência das características do biocarvão para uma melhor adsorção de dióxido de carbono, que determinam uma menor ou maior captura de carbono, como porosidade, presença de grupos funcionais e teor de carbono, foi apresentada no fluxograma representado pela Figura 27 com os pontos de ajuste de cada característica que precisam ser armazenados no banco de dados para avaliar o melhor coeficiente de temperatura, pressão, tempo de residência e outros parâmetros de controle no reator de pirólise.

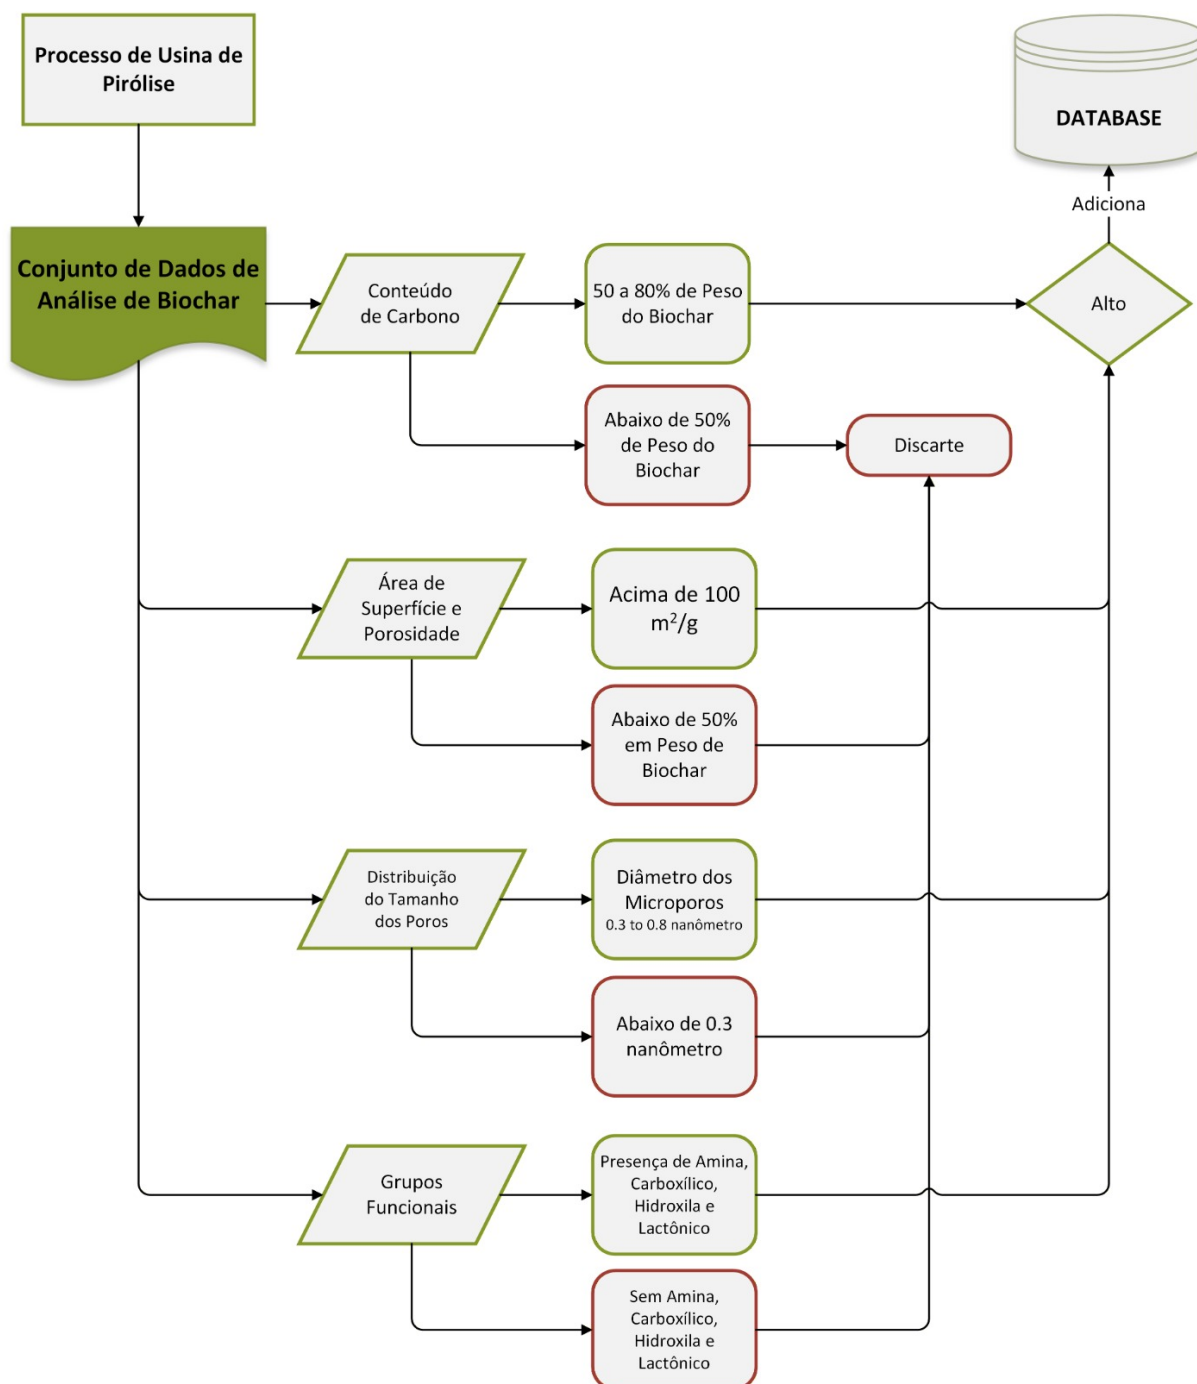


Figura 27 – Fluxograma da avaliação das características do biocarvão para otimização da adsorção de dióxido de carbono e inserção em banco de dados.

Fonte: Adaptado de (TOMCZYK; SOKOŁOWSKA; BOGUTA, 2020)(LI; TASNADY, 2023)(GUO; TIAN; WANG, 2022)(GUO *et al.*, 2022).

Este banco de dados fornece as informações que serão utilizadas na linguagem de consulta estruturada para o CLP (Controlador Lógico Programável) e o algoritmo de IA (Inteligência Artificial), os quais, quando sincronizados, permitem o estabelecimento de condições de controle que otimizam a adsorção de dióxido de carbono no solo ou a captura direta do ar.

Monfort *et al* (MONFORT *et al.*, 2025) focou na pirólise para estabelecer um sistema de descarbonização de menor custo até 2045 na Alemanha, avaliando o potencial de geração de

13,4 TWh de eletricidade e a produção de 10,5 megatoneladas (Mt) de biocarvão, que poderiam capturar 28,3 Mt de emissões de CO₂ com a tecnologia térmica.

A pirólise é um sistema energético que proporciona despacho de eletricidade renovável e emissões negativas, utilizando biochar, instalações de adsorção de carbono, calor e matéria-prima química, com resíduos de biomassa e outros rejeitos como elemento estratégico para alcançar emissões líquidas zero no planejamento energético (SANDHAAS; HARTMANN, 2025).

Avaliar, diagnosticar e mitigar cada tipo de ataque cibernético é importante para contribuir com a resiliência do sistema e diminuir as chances de redução das emissões agregadas na produção de biochar na tecnologia de pirólise.

Rede neural artificial de alimentação direta, conforme apresentado na tabela 21 estima a temperatura de saída e avaliar o tempo de residência do biochar no solo, reduzindo o uso de fertilizantes, indicando os parâmetros ótimos para o processo de pirólise, incluindo pressão, controle de temperatura e tempo de residência no reator de pirólise. (BONG; SELVARAJOO; ARUMUGASAMY, 2022)

Os inversores são responsáveis pelos parâmetros de controle no reator de pirólise, afetando a composição do gás de síntese e do biochar, uma vez que os códigos de comando só podem ser alterados na comunicação com os proprietários do reator de pirólise.

O diagnóstico de falhas favorece a implementação do algoritmo k-vizinhos mais próximos devido à sua adaptabilidade e precisão de classificação, bem como à facilidade de aplicação desse modelo em sistemas de energia renovável com alto desempenho, o que é essencial para a manutenção preditiva (GBASHI *et al.*, 2025).

A tabela 21 Indicar um mecanismo de estrutura específico que integre modelos de IA/ML para detectar e mitigar o ataque cibernético de acordo com o tipo estabelecido na Figura 25 atribuído no dispositivo de um sistema de pirólise lenta.

A restrição de acesso poderia ser inserida nessas ocasiões a partir da avaliação de séries temporais por meio de algoritmos como Aprendizado por Reforço Ator-Crítico e Redes Neurais Artificiais (RNA) para aumentar a resiliência do sistema de controle de pirólise, conforme mostrado na tabela 21.

Tabela 21 – Inteligência artificial/Aprendizado de máquina para aumentar a resiliência e descarbonização contra ataques cibernéticos em usinas de energia de pirólise.

Dispositivo	Tempo de ataque	Mecanismo de resiliência com estrutura de IA/ML	Adaptado de Ref.
CLP	FDI - Ataque em SQL	Rede neural artificial de alimentação direta, sob condições de pressão e temperatura, enviada para o banco de dados do IHM (Interface Homem-Máquina) quanto ao tempo de resiliência do lodo medido em um processador, alcançado em 2 horas para o tempo de resiliência do lodo de esgoto municipal a 750°C dentro do reator de pirólise..	(HALALSHEH <i>et al.</i> , 2024)(SENGAN <i>et al.</i> , 2021)(BONG; SELVA-RAJOO; ARU-MUGA-SAMY, 2022)
Inversor do parafuso de alimentação	FDI - Ataque de comando	Método de RNA (Rede Neural Artificial) para detectar e mitigar ataques de interferência de combustível (FDI) no controlador do dispositivo de alimentação do sistema de pirólise para produzir biochar com excelente adsorção de dióxido de carbono.	(HABIBI <i>et al.</i> , 2021)
Inversor da bomba de água	FDI - Ataque de comando.	Aprendizado por reforço ator-crítico na comunicação entre sensor de nível de água e controladores de inversores.	(MAZARE; RAMEZANI, 2024)
Inversor do soprador de ar para gás de síntese	FDI - Ataque de comando.	Redes LSTM convolucionais gráficas para avaliar a classificação de séries temporais na detecção de comportamentos anômalos em sopradores de ar..	(HABIBI <i>et al.</i> , 2021)
Alarme na IHM	FDI - Ataque de comando.	O algoritmo K-vizinhos mais próximos apresenta alta precisão de avaliação e é viável para aplicação industrial em tempo real, como em usinas de pirólise.	(ZHANG; GAO; QU, 2025)(GBASHI <i>et al.</i> , 2025)
PLC	DoS/DDos - Tráfego de ataque	Aprendizado profundo (DL) e LSTM para identificar padrões únicos de ataques relacionados ao monitoramento da geração de energia no sistema de pirólise, e um classificador Random Forest com recurso de retrocesso (Looking-Back-enabled) para mitigar esses ataques.	(FAHEEM; AL-KHASAWNEH, 2024)(MIHOUB <i>et al.</i> , 2022)

4.1 ESTRUTURA TECNOLÓGICA PARA ELEVAR CRÉDITO DE CARBONO ATRAVÉS DE BIOCARVÃO COM DIFERENTES NORMAS REGULAMENTADORAS

4.1.1 Introdução sobre a estrutura tecnológica

Uma estrutura para reduzir os desafios da aceitação do biochar no mercado, considerando diferentes padrões regulatórios, tem potencial para introduzir um mecanismo que possa mitigar as emissões de carbono em diferentes países. A avaliação das perspectivas de ativadores para capacidade de adsorção, as barreiras para a comercialização de carbono a partir de resíduos de biomassa para a produção de biochar e a investigação de sistemas funcionais para otimizar operações de baixo carbono representam parte deste trabalho. A metodologia apresentada neste artigo contribui para o crescimento do mercado de biochar e para a captura de carbono a partir de diferentes resíduos de biomassa.

A captura de dióxido de carbono e a aplicação do biochar proveniente de lodo de esgoto ou resíduos de biomassa como matéria-prima na indústria química representam uma solução sustentável para atingir a meta global de redução das emissões de gases de efeito estufa (YOON *et al.*, 2025).

O lodo de esgoto é um material rico em nitrogênio, fósforo e matéria orgânica que, após tratamento adequado e economicamente viável, pode se tornar uma solução ambientalmente amigável na forma de aditivos e fertilizantes (SUGURBEKOVA *et al.*, 2023).

Estudos sobre o quadro político e análises de investimentos estratégicos em diferentes países oferecem uma ferramenta potencial para promover a implementação em larga escala e melhorar a aceitação pública (HANSON; NWAKILE; HAMMED, 2025).

Sajdak *et al.* (SAJDAK *et al.*, 2023) demonstraram que a aplicação de biocarvão de lodo de esgoto no solo em áreas degradadas e industriais abandonadas na Europa capturaria entre 23 e 84 milhões de toneladas métricas de CO₂ até 2055, com 4 cenários propostos, considerando a infiltração de água, a drenagem e a absorção de nutrientes.

Países em desenvolvimento e populosos precisam implementar métodos de baixo custo para produzir biochar a partir de lodo de esgoto, empregando-o na agricultura local com tratamento ideal e padrões internacionais, visto que 50% do lodo de esgoto é produzido pelos sete países mais populosos do mundo (GHORBANI *et al.*, 2022).

Anokye (ANOKYE, 2024) estimaram que a bioenergia, com a produção de biochar, poderia suprir 6,15% da demanda de Gana, contribuindo para a melhoria da fertilidade do solo e, consequentemente, para o aumento da produtividade agrícola e para o comércio de carbono.

Neogi *et al.* (NEOGI *et al.*, 2022) avaliaram que a tendência do biochar projetado é o aumento dos grupos funcionais desejados e a atribuição de melhores propriedades de superfície em diferentes tipos de solo.

A tomada de decisão multicritério é um método que identifica a solução ideal para o biochar em relação à sua versatilidade como corretivo de solo, sequestro de carbono e bio-combustível, contribuindo para o desenvolvimento de materiais de alto desempenho à base de

biochar(SANTOS *et al.*, 2025).

Ao avaliar diferentes tempos de residência, a pirólise lenta é o processo que gera maior volume em comparação com a pirólise rápida, sendo viável em pequena escala com preços de mercado abaixo de US\$ 12,14 e US\$ 100,73/MT quando o custo de compensação de carbono é de US\$ 1 e US\$ 31/MT CO₂, respectivamente. (AHMED *et al.*, 2024).

Li *et al.* (LI *et al.*, 2023) realizou uma pesquisa comparativa de liquefação hidrotérmica, pirólise e incineração com o software OpenLCA e o banco de dados Ecoinvent para o tratamento térmico de lodo de esgoto, e os resultados mostraram que a primeira e a segunda tecnologias são ambientalmente amigáveis, especialmente no cenário de eletricidade verde como energia de entrada, sendo que a liquefação hidrotérmica apresentou o melhor potencial de redução de carbono entre as três tecnologias avaliadas.

Muniz *et al.* (MUNIZ *et al.*, 2025) avaliaram o potencial de descarbonização do lodo de esgoto considerando sensores avançados e a aplicação de inteligência artificial.

A previsão da precisão da captura de carbono com biochar ativado por KOH, avaliada por meio de aprendizado de máquina, indica os parâmetros de influência mais significativos e contribui para otimizar a adsorção de emissões de gases de efeito estufa, regulando a temperatura, a pressão e outros fatores importantes avaliados na ferramenta de inteligência artificial do processo de pirólise (HASSAN; BAGHBAN, 2025).

A gaseificação do biochar é uma via para reduzir as emissões de dióxido de carbono, operando em diferentes temperaturas de 700 °C, 800 °C e 900 °C, com uma vazão de 5 litros/min, convertendo 57,1% do CO na temperatura mais alta. (OFUANI; BHOI, 2024).

Vrimnavcova *et al.* (ŘIMNÁČOVÁ *et al.*, 2024) realizaram a carbonização lenta do lodo de esgoto seco foi realizada a temperaturas entre 400°C e 900°C, atingindo 0,415 mmol/g na temperatura máxima e 0,212 mmol/g na temperatura mínima. Essa capacidade de adsorção poderia ser melhorada utilizando um processo de ativação sob certas circunstâncias.

O biochar com alta ultramicroporosidade é produzido a partir de biomassa com alto teor de lignina e celulose, e deve ser pirolisado a altas temperaturas (NAVARRO *et al.*, 2025).

A integração do biochar na geração de hidrogênio e eletricidade ajuda a reduzir o uso de combustíveis fósseis e apoia a transição para energias mais limpas, visto que as normas internacionais apontam o potencial do biochar para o armazenamento de carbono por centenas ou milhares de anos (MATARRU; SHIN, 2025).

Buss *et al.* (BUSS *et al.*, 2022) avaliaram que a adição de minerais ao biochar poderia diminuir em 17% os custos de remoção de dióxido de carbono devido à redução da perda de carbono durante a pirólise e impulsionar os incentivos para fertilizantes de liberação controlada.

Algumas limitações na produção, qualidade e escala do biochar a partir da pirólise de lodo de esgoto municipal exigem perspectivas futuras, como a melhoria das propriedades e a aplicação de aditivos, catalisadores e novos projetos de reatores para aumentar a relação custo-benefício e a eficiência do processo(GUSIATIN; KULIKOWSKA; BERNAT, 2024).

Aditivos à base de cálcio aumentam a proporção de adsorção de CO₂ na copirólise de

lodo de esgoto e biomassa, incrementando a massa do biochar, o pH, a área superficial, o volume total de poros e aumentando o teor de carbono orgânico dissolvido (CAI *et al.*, 2024b).

He *et al.* (HE *et al.*, 2025) demonstraram que as propriedades físico-químicas do biochar, com desempenho superior e configuração eletrônica favorável, podem aumentar a resistência à decomposição bioquímica e apresentar maior adsorção de carbono do solo contendo gases de efeito estufa. A aplicação de biochar nesses solos alcançou uma redução líquida de emissões de 435,51 kg CO₂eq/ha em comparação com o fertilizante NPK.

Liu *et al.* (LIU *et al.*, 2023a) realizou a preparação de um biochar derivado de lodo condicionado com K₂FeO₄ aumentou a capacidade de adsorção de CO₂ de 75,69 mg/g para 81,68 mg/g, o que aprimora as propriedades químicas, como o aumento do teor de carbono e da quantidade de grupos amino na superfície do biochar, melhorando a reutilização e o desempenho econômico.

Sun *et al.* (SUN *et al.*, 2022) quantificaram a pegada de carbono por meio de uma avaliação do ciclo de vida, estimando-se que 20 toneladas de lodo de esgoto industrial atingem um sequestro líquido de carbono de 1120,1 e 1354,5 kg CO₂e por unidade funcional (UF) quando aplicadas em terras agrícolas e aterros sanitários, respectivamente.

O carvão resultante da pirólise de lodo de esgoto é um material promissor para a redução de CO₂ e descarte de resíduos. O material obtido, ativado com uma quantidade menor de hidróxido alcalino e tratado com cloreto ácido, apresenta melhorias na estrutura e textura da superfície, aumentando a eficiência de separação e recuperação de CO₂ (MIRICIOIU *et al.*, 2021).

Um roteiro claro e abrangente é imprescindível para o desenvolvimento do mercado de carbono em diferentes sistemas, conforme avaliado e relacionado por Zhang *et al.* (ZHANG *et al.*, 2024b) que comparou o Sistema de Comércio de Emissões da União Europeia (EU ETS), a Iniciativa Regional de Gases de Efeito Estufa (RGGI) nos EUA e o sistema de negociação de câmbio da China (CFETS) e determinou três etapas para estabelecer um mercado robusto de créditos de carbono, sendo a primeira a estratégia de mercado ou roteiro com metas e regras definidas, a segunda etapa que consistirá em mecanismos flexíveis para manter o equilíbrio do mercado em meio a flutuações e a terceira etapa uma infraestrutura de plataforma diversificada visando otimizar a liquidez e a competitividade do mercado.

O Sistema Brasileiro de Comércio de Carbono (SBCE) anunciou uma meta de emissões líquidas zero até 2050, com grande vantagem competitiva nas atividades florestais e agrícolas, cujo uso da terra beneficia o comércio internacional de carbono (MOTTA, 2023).

Layek *et al.* (LAYEK *et al.*, 2022) investigaram a aplicação de biochar, produzido a partir de madeira, especialmente agulhas e cascas de pinheiro, em hotéis à beira da estrada na região do Himalaia Oriental, que minimiza a erosão do solo e a perda de nutrientes nas encostas, podendo ser um candidato potencial para captura e armazenamento de carbono a longo prazo no nordeste da Índia.

Os desafios para os adsorventes verdes derivados de lodo de esgoto incluem a qualidade

e a uniformidade, além da atual relação custo-benefício após investimentos em equipamentos, mão de obra e manutenção, bem como a compatibilidade ambiental e a biodegradabilidade em diferentes tipos de solo (SHARMA; GHODKE; CHEN, 2024).

A estabilidade estrutural do carbono no biochar, para fins de créditos de carbono, depende principalmente do tipo de matéria-prima. Algumas biomassas apresentam alta estabilidade, garantindo a confiabilidade dos créditos de carbono. Algumas técnicas para medir a estabilidade do carbono no biochar são a fração termoestável e a meia-vida do carbono (ADHIKARI *et al.*, 2024).

A falta de transparência na cadeia de suprimentos de biomassa é a barreira mais importante para a produção em larga escala de biochar, seguida pelos custos associados à geração de biomassa de baixo valor com boas características e localização, pelos padrões de preços do biochar, pelo acesso a capital e pelas flutuações do mercado de créditos de carbono (ELIAS *et al.*, 2024).

Existem diferentes certificações de biochar, como a Certificação Europeia de Biochar (EBC), a Iniciativa de Biochar da Austrália e Nova Zelândia (ANZBI), o padrão de biochar para a indústria agrícola na China (CNAIS), os padrões de biochar nos EUA e o reconhecimento mútuo de padrões ou um padrão internacional de biochar globalmente reconhecido. O processo de criação de uma certificação mundial de biochar facilitaria o potencial do ecossistema a longo prazo para sequestrar carbono (LIN *et al.*, 2025).

A rentabilidade do biochar nas fábricas de papel dos EUA para sequestro de carbono depende de custos de fabricação mais baixos, preços mais altos dos créditos de carbono, subsídios federais e custos de transporte, visto que o mercado de créditos de carbono apresenta altos custos de verificação e requisitos complexos, exigindo uma estrutura econômica resiliente para avaliar as tendências e flutuações desses valores (KADAM; DWIVEDI; MARRERO, 2025).

Aumentar o conhecimento sobre as formas de aplicação do biochar em diferentes tipos de propriedades agrícolas por meio de programas de treinamento e demonstração, desenvolver diretrizes de qualidade e segurança e identificar os aspectos socioculturais e econômicos para a adoção regional do biochar (JANISZEWSKA-LATTERINI *et al.*, 2025).

4.1.2 Metodologia da estrutura de certificação de baixo carbono

A estrutura de certificação de baixo carbono precisa auxiliar os formuladores de políticas, os organismos de certificação e as autoridades públicas a estabelecer o desempenho ambiental geral e otimizar a operação para proporcionar redução de tempo e custos (BARTZAS *et al.*, 2024).

Evitar práticas de greenwashing e atribuir preocupações com a integridade ambiental como efeitos sociais adversos para o mercado voluntário de carbono é importante para uma estrutura que certifique empresas, reduzindo os riscos à reputação e permitindo que alcancem a meta de emissões líquidas zero (KREIBICH, 2024). Uma certificação robusta por terceiros em empresas chinesas reduz a assimetria de informações e permite a adoção de perspectivas

estratégicas com medidas avançadas e confiáveis para demonstrar aos stakeholders a contribuição para a adoção de práticas sustentáveis e garantir esforços ambientais genuínos para alcançar a mitigação das mudanças climáticas globais (BATTISTI *et al.*, 2025).

A mensuração da sustentabilidade energética utilizando uma nova estrutura foi avaliada por Muniz *et al.* (MUNIZ *et al.*, 2020) que comparou e verificou diferentes índices e indicadores para obter uma metodologia inovadora que avaliou diversas ferramentas computacionais sustentáveis.

A estrutura para aprimorar o mecanismo de negociação de carbono deve se basear no conceito de criação de uma plataforma digital com um mecanismo de relatórios transparente e padrões de verificação rigorosos para gerar confiança e atrair investimentos, com soluções tecnológicas avançadas que otimizem as transações de remoção de carbono e facilitem a comunicação em tempo real, incluindo métricas de desempenho e tendências de mercado (TANVEER; ISHAQ; HOANG, 2024).

Muniz *et al.* (MUNIZ *et al.*, 2023) realizaram uma revisão para desenvolver um conceito de sustentabilidade com foco em energia, visando formular políticas eficazes e tomar decisões informadas para monitorar o progresso dos indicadores de fatores energéticos.

Existem cinco fatores que impactam a financeirização do mercado de carbono, segundo Wei *et al.* (WEI *et al.*, 2025) consistindo em preços de ações de empresas de energia elétrica, taxa de juros dos fundos federais, preço do petróleo bruto WTI, condições climáticas como precipitação e instrumentos de política.

Estabelecer instituições de mercado de captura de carbono com um mercado de conformidade, registro de carbono e estrutura legislativa, compensando efetivamente os potenciais perdedores, incentivando as indústrias de alta emissão a adotarem tecnologias de baixo carbono, visto que os principais compradores de créditos de carbono são corporações multinacionais e instituições financeiras em países de renda média-alta, explorando o surgimento de uma coalizão de mercado pró-redução de carbono (STEK; OLIVEIRA; VASUDHEVAN, 2025).

Foco na eficiência de custos, potencial da biomassa, incentivos econômicos, percepção da sociedade, cadeias de valor, disponibilidade de tecnologias e tendências de previsão, avaliando a necessidade regional para estabelecer um plano nacional para atingir as metas de emissões líquidas zero (WOLLNIK *et al.*, 2025).

Determinar o nível de regulamentação e inovação associado a mandatos regulamentados, projetos de ampliação de escala, precificação de carbono plenamente implementada e incentivos à implantação são ferramentas importantes para avaliar os desafios em diferentes padrões regulatórios de economias emergentes (SCHENUIT *et al.*, 2025).

A taxa de crescimento da produção de biochar e os requisitos de qualidade são fatores-chave para expandir o mercado de carbono, com a formação de práticas operacionais que orientem diferentes tipos de biomassa, em conjunto com maior rentabilidade e viabilidade econômica (JUUSO *et al.*, 2025).

As fintechs têm potencial para impactos diretos e indiretos nas emissões de carbono

corporativas, à medida que estabelecem a diversificação dos serviços financeiros para fornecer empréstimos P2P e tecnologia blockchain, oferecendo opções de financiamento flexíveis e escritórios financeiros sem papel, facilitando o financiamento da cadeia de suprimentos verde e contribuindo para a eficiência energética, agregando uma gestão de baixo carbono no apoio financeiro(WANG *et al.*, 2024).

Pierson *et al.* (PIERSON *et al.*, 2024) verificaram que a importância do apoio informativo sobre os diferentes benefícios do solo em diversas concentrações e processos de biochar, conectando fornecedores de biochar com gestores de terras e créditos de carbono para benefícios econômicos mútuos, de acordo com as normas regulamentares, incluindo metas para a produção de biochar..

A otimização dos parâmetros do biochar na aplicação agrícola depende da análise físico-química da matéria-prima, da máxima eficiência energética e da relação custo-benefício(PATEL; PANWAR, 2024).

Avaliação de locais ideais para localização estratégica em análises quantitativas e qualitativas, redução de custos de matéria-prima com a inserção de unidades portáteis e monitoramento da demanda de mercado(AHMED *et al.*, 2025).

Os produtores e fornecedores de biochar poderiam aumentar a rentabilidade desenvolvendo modelos espaciais econômicos e ambientais, facilitando a identificação de regiões vantajosas e necessidades políticas, indicando a variabilidade geográfica e as estratégias de produção (TANG; LI; COCKERILL, 2024).

O período de retorno do investimento do biochar tem potencial para ser melhorado na produção em processos direcionados a nichos de mercado de alta tecnologia, como catalisador avançado para a degradação de poluentes e alternativa agregada na construção civil, contribuindo com a captura e adsorção de carbono e alta lucratividade(ZHANG *et al.*, 2024).

Petersen & Sanei (PETERSEN; SANEI, 2025) avaliaram que a necessidade de integração da razão molar H/C com o método de refletância aleatória (R_o) para uma estimativa precisa do potencial de sequestro de carbono a longo prazo, fornecendo distribuição espacial e reduzindo incertezas.

Maximizar a recuperação de biochar otimiza o processo de produção e aumenta a rentabilidade. Um maior rendimento de biochar reduz a produção de gás de síntese como óleo de pirólise, limitando as vendas do produto e afetando a economia geral da planta(TROLLIP; MERCKEL, 2025).

Rubel & Wei (RUBEL; WEI, 2025) avaliaram que o custo de produção para a viabilidade econômica de fertilizantes nitrogenados de liberação controlada à base de biochar, verificando-se que o preço de venda de equilíbrio foi estimado em US\$ 1,24/kg, US\$ 1,02/kg e US\$ 0,98/kg para produção em pequena, média e grande escala, respectivamente, e a expansão da capacidade de produção por meio de operações em múltiplos turnos melhoraria a competitividade no mercado.

4.1.3 Resultados e discussão sobre o desenvolvimento de ferramentas tecnológicas para elevar o alcance de créditos de carbono

Otimizar as decisões com a integração de estruturas que combinam diferentes ferramentas para reduzir os desafios relacionados aos padrões de certificação de créditos de carbono, alinhando a redução de carbono e a lucratividade, pode aumentar a produção dos fabricantes de sistemas de captura de carbono.

Os padrões de qualidade do biochar, parâmetro crucial no sistema de captura de carbono e comércio de emissões, dependem de critérios estabelecidos por organizações associadas que certificam o produto por meio de testes e amostragem, seguindo diretrizes específicas.

A figura 28 representada por um fluxograma, apresentam cinco padrões de qualidade em diferentes países, mostrando parâmetros importantes para aumentar a captura de carbono e certificar a estabilidade do carbono contido no biochar no solo.

Desenvolver estruturas que relacionem novas tecnologias para promover maior rentabilidade financeira em diferentes mercados de carbono, colaborando com a estruturação e organização de proprietários de usinas de pirólise e outras usinas de energia que produzem materiais sólidos para adsorção de carbono.

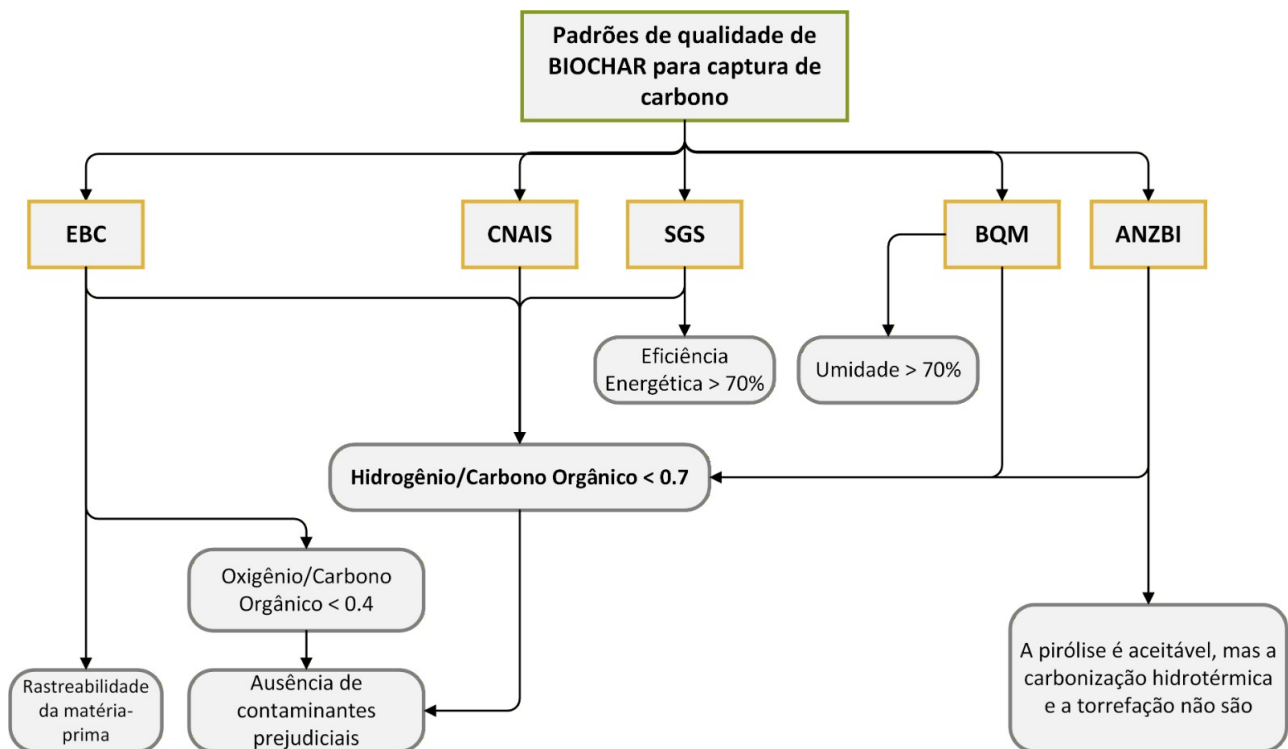


Figura 28 – Parâmetros do biochar para melhorar a captura de carbono em diferentes padrões de qualidade.

Opções de financiamento flexíveis com Fintechs, considerando as particularidades regionais e da biomassa de acordo com a produção de biochar, os preços da matéria-prima e o volume como garantia, com a tokenização desses ativos, contribuem para projetos mais rentáveis.

A avaliação das propriedades químicas e físicas para aumentar o preço de venda comercial, o rendimento, o número de microporos e o teor de carbono, visando a redução das emissões, é crucial para o crescimento do mercado de biochar e requer a previsão dos custos de produção e das tendências de lucro.

Visando aumentar a rentabilidade do biochar, foi desenvolvido neste artigo o fluxograma apresentado na figura 29 propondo novas tecnologias que possam reduzir os custos e alguns desafios que tornam inviáveis projetos de captura de carbono devido à menor eficiência de custos e à redução das cadeias de valor ou das possibilidades de financiamento.

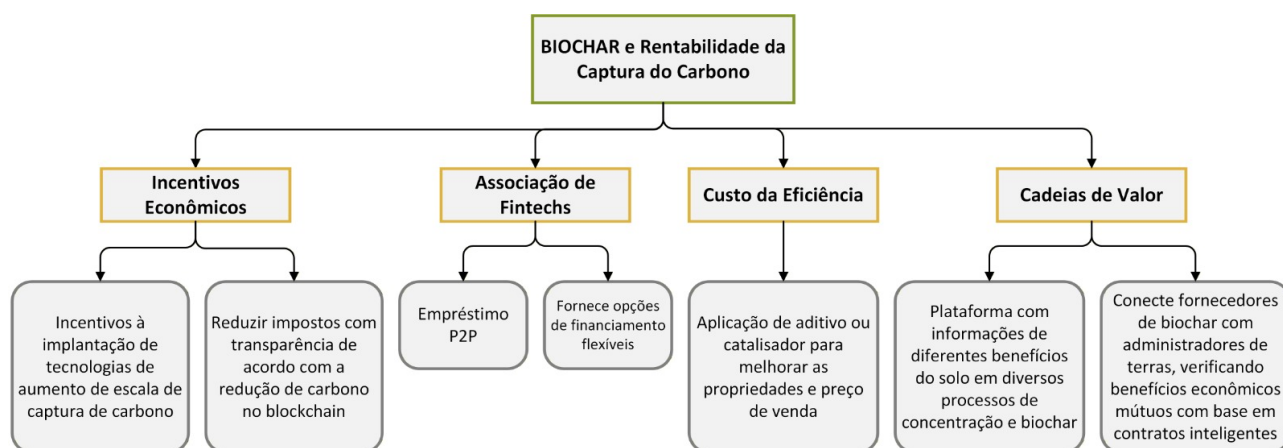


Figura 29 – Ferramentas tecnológicas para reduzir os desafios no mercado de biochar e aumentar a rentabilidade da captura de carbono.

Introduzir ferramentas de IA para realizar essas tarefas de correlação entre as propriedades do biochar e a avaliação de preços na cadeia de suprimentos para diferentes tipos de biomassa e tendências de mercado, proporcionando melhores preços de venda no planejamento de curto e longo prazo, com a operação eficiente de sistemas de tratamento térmico.

Informações para gestores de terras sobre a produtividade com a aplicação de biochar no solo de diferentes culturas exigem pesquisas extensivas e diretrizes para processos industriais e financiamento verde.

Estabelecer conexões com gestores de terras que tenham potencial para aumentar a produção agrícola com a inserção de biochar no solo, com base em contratos inteligentes e sistemas blockchain com sensores como registro de monitoramento da rentabilidade na cadeia de valor, poderia reduzir as barreiras na cadeia de suprimentos de biochar. A figura 30 apresentou o quadro da perspectiva avaliada da pesquisa.

Integrar tecnologias financeiras associadas a benefícios na eficiência ambiental da mitigação da poluição nos mercados agrícola ou florestal, melhorando a transparência no acesso à informação, contribuindo para a avaliação da captura de carbono e reduzindo os desafios para a certificação de créditos.

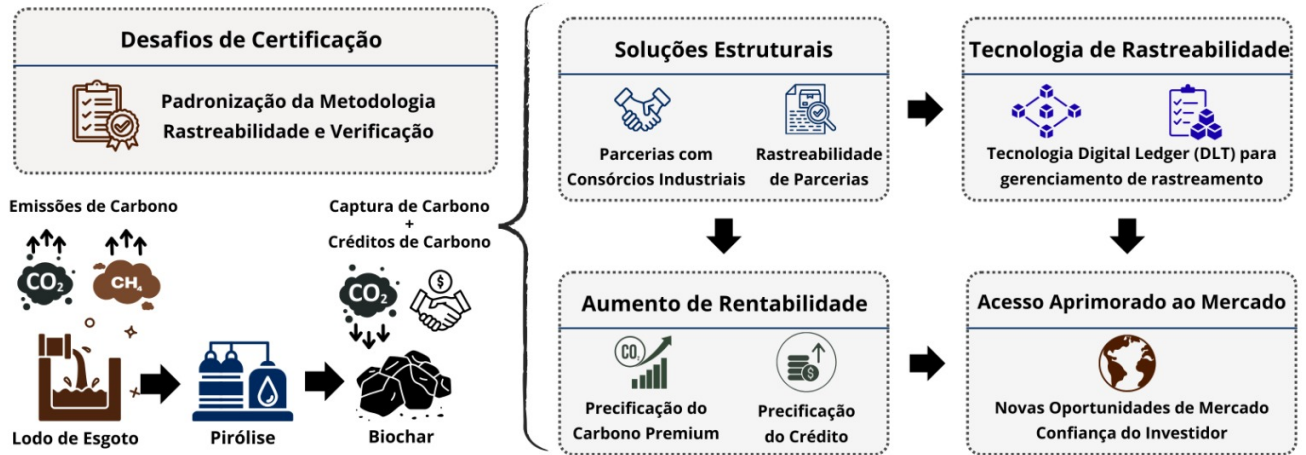


Figura 30 – Estrutura para aumentar a captura de carbono e a rentabilidade do biochar.

4.2 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Detectar e mitigar ataques cibernéticos para melhorar a descarbonização é uma tarefa complexa que exige diferentes métodos de IA/ML, sendo uma direção auxiliar para a transição energética a partir do tratamento térmico de lodo, reconhecido como solução ecológica, colaborando com o planejamento da estratégia de defesa no sistema eletrônico de uma usina de pirólise para melhorar a resiliência com base em energias renováveis.

Desenvolver um quadro de referência que vise reduzir os desafios à inserção do biochar derivado de resíduos de biomassa em diferentes sistemas de comércio de emissões, contribui para maiores investimentos nesta solução de captura de carbono e serve como referência para outras tecnologias sustentáveis, mitiga emissões e colabora para a redução dos poluentes climáticos.

Fornecer diferentes fluxogramas e tabelas comparativas para apresentar soluções tecnológicas viáveis para a adição de biochar em diversos sistemas de comércio de emissões, com a incorporação da adsorção de carbono no solo e vários padrões de qualidade é vital para a estruturação das ferramentas de captura de carbono e sua rentabilidade.

A integração de diferentes ferramentas inovadoras que alinhem o objetivo de rentabilidade e maximização da redução de carbono reduz os desafios econômicos em diferentes escalas e as barreiras de mercado do biochar para diferentes biomassas, fornecendo um material para aumentar a perspectiva de novas pesquisas sobre a eficácia da captura de carbono a partir de carvão vegetal derivado de resíduos de biomassa na biogeoquímica do solo.

5 CONSIDERAÇÕES FINAIS

A aplicação de aprendizado de máquina no setor energético tem se destacado como uma abordagem promissora para enfrentar os desafios da transição energética e da sustentabilidade ambiental. No contexto das usinas termelétricas de biomassa, o uso dessas tecnologias pode potencializar a eficiência operacional, melhorar a previsibilidade de processos e otimizar as estratégias de descarbonização. Essa pesquisa busca explorar e validar a viabilidade do aprendizado de máquina como ferramenta para aprimorar a sustentabilidade energética dessas usinas, focando em dois objetivos principais: a previsão precisa de emissões de carbono e a otimização de parâmetros operacionais para reduzir impactos ambientais.

Otimizar a geração de energia elétrica em usinas de biomassa, classificando estratégias e ferramentas computacionais para sustentabilidade visando abordar lacunas de oportunidade para produtividade em usinas, de modo a avaliar diferentes políticas e estratégias operacionais que garantam robustez na tomada de decisões com a previsão de séries temporais de carga e despacho.

O aumento nas taxas de descarbonização dentro do processo de geração da eletricidade por meio da maior demanda devido a população brasileira e mundial crescendo, que tende a possuir maior participação da energia renovável necessita de ferramentas que executem a previsão para aprimorar a eficiência de Usinas dentro do SIN no Brasil e expandir estas para outros países do mundo como Espanha, Itália de acordo com as políticas de comercialização dos créditos de carbono e previsão de carga da geração estimada para anos seguintes.

Ao identificar e reduzir incertezas futuras com modelos de aprendizado de máquina pode garantir contratos de compras de energia de longo prazo que facilitam financiamentos bancários com menores juros pois tem potencial de garantir que Usinas não necessitem efetuar pagamento de multas por sub-entrega de energia previamente comercializada, planejar melhor plantios e colheitas reduzindo compra no mercado spot devido a escassez de matéria prima se usado modelos que avaliem e realizem previsão associado com condições climáticas.

Os resultados indicam que os modelos baseados em IA podem ser treinados para identificar padrões complexos nos dados operacionais das usinas, permitindo previsões mais assertivas sobre emissões e desempenho energético. Além disso, as técnicas de otimização baseadas em algoritmos inteligentes oferecem soluções práticas para reduzir as emissões de gases de efeito estufa, ao mesmo tempo em que mantêm ou aumentam a eficiência do processo de conversão de biomassa em energia. Isso contribui diretamente para os compromissos globais de descarbonização e para o fortalecimento da matriz energética sustentável.

Avanços no setor de energia garantem mercados mais rápidos a partir da programação com precisão de previsão que permitem o desenvolvimento do mercado de capacidade para permitir confiabilidade com resposta de frequência e despacho de acordo com sinais de preço de curto prazo e possibilita obtenção de informações de alta qualidade sobre condições de mercado e redução das emissões de carbono.

Nos segmentos agrícola e florestal a partir da biomassa residual dentro do Brasil pode ocorrer maior número na instalações de Usinas a partir desses algoritmos desenvolvidos na tese após integrar ajustes para que prevejam secas de reservatórios de hidroelétricas em condições climáticas desfavoráveis que eleva a necessidade da geração de eletricidade com florestas energéticas ou resíduos agrícolas, podendo verificar se há vantagem em produzir celulose ou etanol ou gerar energia elétrica e em usinas de etanol de milho possibilita abastecer com maior eficiência estratégica as caldeiras de geração de eletricidade evitando desperdício de combustível com geração de energia elétrica que não será despachada.

Projetar retornos financeiros com modelos de previsão de garantia física no abastecimento a partir de diferentes biomassas residuais da cana de açúcar e milho responsáveis para geração de etanol e que produzem energia elétrica como insumo para produção deste combustível e finalidade secundária de comercialização de eletricidade. Estes algoritmos podem prever ajustes de valores do gás natural em que pode ser verificada a competitividade com diferentes biomassas para geração de eletricidade no Brasil e outros países.

Associar produtividade agrícola e maior eficiência na geração de eletricidade por tonelada de biomassa residual de modo a apresentar maior viabilidade econômica para a instalação de usinas de pirólise que realizem o tratamento térmico com menores perdas do calor e da energia gerada durante o processo e dentro da automação destas, avaliar a previsão de carga necessária e comercializar a remoção de poluentes a partir de biocarvão com créditos de carbono.

Existem vários caminhos para pesquisa e desenvolvimento futuro na previsão de séries temporais CNN-LSTM. Usar outros modelos CNN para detectar características do sinal pode ser uma alternativa para melhorar a previsão. Considerando que a umidade e a temperatura influenciam o nível das barragens nas hidrelétricas, e o uso da geração térmica está relacionado à falta de água disponível para a hidrelétrica, seria promissor utilizar essas informações como co-características para melhorar as previsões sobre cada uma das usinas.

Investigar, desenvolver e aplicar diferentes associações de modelos colabora com a criação de um banco de dados que permita identificar maior eficiência em determinados algoritmos dentro da melhoria de previsão de demanda e outros aspectos que possibilite menor emissão de poluentes e seriam de mais difícil identificação manualmente, permitindo maior expansão do número de usinas de tratamento térmico para geração de eletricidade.

Aumentar a confiança de investidores a partir de algoritmos que garantem uma previsibilidade do recebimento dos valores da geração de eletricidade com alta eficácia, minimiza custos de financiamento que revertem em queda de juros para projetos de médio até grande porte em Usinas que despacham eletricidade ao SIN a partir de biomassa residual.

Integrar modelos de IA em Usinas pode contribuir para elevar o nível de inovação em projetos com subvenção econômica, facilitando o financiamento de recursos por criar simulações que processam o ambiente real e prever ganhos de geração em diferentes usinas termelétricas.

Em síntese, a aplicação de aprendizado de máquina nas usinas termelétricas de biomassa demonstra potencial significativo para promover a sustentabilidade energética e mitigar

as mudanças climáticas. Este trabalho estabelece uma base promissora para estudos futuros, ressaltando a necessidade de aprofundamento das análises e da adaptação das ferramentas às realidades específicas das usinas e das condições locais de operação.

Viabilizar a sustentabilidade energética aprimorando a eficiência de usinas por meio de algoritmos de IA com simulação computacional e processar informações sobre diferentes despachos de eletricidade de modo a permitir melhorias nos aspectos ambiental, institucional e social é crucial para prospectar a tecnologia no meio científico e industrial.

Mecanismos que aprimoram a cyber segurança a partir de diferentes algoritmos de IA avaliados durante a tese, contribuem para que tecnologias térmicas de tratamento de resíduos para geração de eletricidade tenham sua efetividade testada e reduzam potencialmente ataques virtuais em IHM e CLPs, essenciais na estabilidade e redução de riscos do processo.

Em processos térmicos como a pirólise que tem capacidade de produzir energia elétrica por meio do ciclo Brayton que possui alta resposta a variações rápidas dependente da qualidade do gás de síntese produzido e por ciclo Rankine variável de acordo com o calor residual proveniente dos subprodutos e de um processo de co-geração nos quais a previsão de series temporais contribui em transições suaves e controladas destes ciclos térmicos e despacho com maior confiabilidade.

O fluxograma desenvolvido em relação as ferramentas de pirólise para o mercado de biocarvão elevar a captura de carbono e lucratividade permite o desenvolvimento de futuras teses focadas no desenvolvimento de produtos tecnológicos para viabilizar a sustentabilidade energética com o tratamento térmico de resíduos que colaborariam para o avanço da transição energética dentro do Brasil e em outros países ao redor do mundo.

5.0.1 Recomendações para trabalhos futuros

Os desafios relacionados à qualidade e disponibilidade de dados, à integração das tecnologias de aprendizado de máquina nos sistemas existentes e à avaliação de custos e benefícios ainda precisam ser superados. Esses fatores reforçam a importância de uma abordagem multidisciplinar que inclua aspectos técnicos, econômicos e ambientais no desenvolvimento de soluções.

Realizar a integração dos sistemas de previsão de carga com contratos inteligentes visando mercados de carbono e títulos verdes em formato de token permitiria maiores ganhos. O desenvolvimento desta ferramenta possibilitaria a aplicação desta em diferentes usinas para maximizar ganhos e elevar a participação de Usinas termoeletricas, reduzir desperdícios em Usinas que operam combustíveis fósseis e não fósseis por otimização operacional e aumentar os lucros na margem operacional por despachar nos horários de preços de liquidação de diferenças (PLD) mais alto.

A metodologia híbrida do modelo de previsão e descarbonização pode ser expandida com a incorporação de variáveis exógenas, como trajetórias de preços de combustíveis, condições climáticas e sinais de mercado, para aprimorar ainda mais a previsão adaptativa. Além disso, explorar a implementação em tempo real com aprendizado online pode permitir a atualização

contínua do modelo à medida que novos dados chegam, aumentando a resiliência a mudanças imprevistas na demanda. No geral, a estrutura CF-CNN-BiLSTM hiperajustada representa um avanço significativo na previsão de geração térmica, abrindo caminho para operações de sistemas de energia mais inteligentes, limpas e eficientes.

Contratos inteligentes permitem serem avaliados remotamente, necessitando menos auditorias dentro da operação por ser criptográfica e imutável, sendo recomendados sua aplicação em conjunto com sistemas de IA e futura aplicação em usina termoelétrica de biomassa. No futuro, a pesquisa deve priorizar o desenvolvimento de estratégias de controle adaptativo, aproveitando modelos de aprendizado de máquina capazes de realizar previsões de curto prazo e otimização de processos de longo prazo, para garantir que as tecnologias de descarbonização permaneçam eficientes e economicamente viáveis sob composições variáveis de matéria-prima e demandas operacionais.

Pesquisas futuras sobre a descarbonização de tratamentos térmicos de lodo devem priorizar o desenvolvimento de uma estrutura integrada, baseada em dados e escalável, que aprimore tanto a sustentabilidade ambiental quanto a eficiência energética. É fundamental dar atenção à otimização dos processos de pré-tratamento de lodo, especialmente no que diz respeito à redução do consumo de energia na desidratação e à compreensão da influência da heterogeneidade da matéria-prima, como teor de umidade e pH, no rendimento do processo. Inovações no projeto de reatores, incluindo a incorporação de materiais resistentes à corrosão e sistemas de integração térmica, são essenciais para o avanço da gaseificação em água supercrítica e outras tecnologias térmicas de alto desempenho. Além disso, a integração de sistemas de captura de carbono economicamente viáveis, especialmente aqueles que utilizam biocarvão ou líquidos iônicos, requer investigação adicional em escala piloto e industrial.

REFERÊNCIAS

- ABBASIMEHR, Hossein; PAKI, Reza. Improving time series forecasting using lstm and attention models. **Journal of Ambient Intelligence and Humanized Computing**, Springer, v. 13, n. 1, p. 673–691, 2022.
- ABDELKADER, Sobhy *et al.* Securing modern power systems: Implementing comprehensive strategies to enhance resilience and reliability against cyber-attacks. **Results in engineering**, Elsevier, p. 102647, 2024.
- ABOUGHALY, Mohamed; FATTAH, IM Rizwanul. Environmental analysis, monitoring, and process control strategy for reduction of greenhouse gaseous emissions in thermochemical reactions. **Atmosphere**, MDPI, v. 14, n. 4, p. 655, 2023.
- ADEBAYO, Tomiwa Sunday; UHUNAMURE, Solomon Eghosa; SHALE, Karabo. A time-varying approach to the nexus between environmental related technologies, renewable energy consumption and environmental sustainability in south africa. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 4860, 2023.
- ADENIYI, Adewale George *et al.* Biomass-derived activated carbon monoliths: A review of production routes, performance, and commercialization potential. **Journal of Cleaner Production**, Elsevier, p. 138711, 2023.
- ADHIKARI, Sirjana; MOON, Ellen; PAZ-FERREIRO, Jorge; TIMMS, Wendy. Comparative analysis of biochar carbon stability methods and implications for carbon credits. **Science of the Total Environment**, Elsevier, v. 914, p. 169607, 2024. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2023.169607>>.
- ADIBIMANESH, Behrouz *et al.* Energy consumption optimization in wastewater treatment plants: machine learning for monitoring incineration of sewage sludge. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 56, p. 103040, 2023.
- AHMAD, Naqash; GHADI, Yazeed; ADNAN, Muhammad; ALI, Mansoor. Load forecasting techniques for power system: Research challenges and survey. **IEEE Access**, IEEE, v. 10, p. 71054–71090, 2022.
- AHMED, Nafisa N; POKHAREL, Raju; MIESEL, Jessica; SAFFRON, Christopher M. Assessing feedstock availability and economic feasibility of utilizing forest biomass for biochar production in stationary and portable systems in michigan. **GCB Bioenergy**, Wiley Online Library, v. 17, n. 5, p. e70030, 2025. Disponível em: <<https://doi.org/10.1111/gcbb.70030>>.
- AHMED, Shams Forruque *et al.* Biochar produced from waste-based feedstocks: Mechanisms, affecting factors, economy, utilization, challenges, and prospects. **GCB Bioenergy**, Wiley Online Library, v. 16, n. 8, p. e13175, 2024. Disponível em: <<https://doi.org/10.1111/gcbb.13175>>.
- AKBARI, M; KHALILARYA, Sh. Emergy and stability analysis of a biomass-fueled combined cycle integrating rankine and brayton cycles with desalination and co2 recycling. **International Journal of Hydrogen Energy**, Elsevier, v. 203, p. 153185, 2026.
- AKBARI, Maryam; KUMAR, Amit. The development of data-intensive techno-economic models for the comparison of renewable natural gas production from six different biomass feedstocks for the decarbonization of energy demand sectors. **Fuel**, Elsevier, v. 358, p. 130107, 2024.

AKINPELU, David *et al.* Machine learning applications in biomass pyrolysis: From biorefinery to end-of-life product management. **Digital Chemical Engineering**, Elsevier, p. 100103, 2023.

AKINYEMI, Ayodeji Stephen; MUSASA, Kabeya; DAVIDSON, Innocent E. Analysis of voltage rise phenomena in electrical power network with high concentration of renewable distributed generations. **Scientific Reports**, Nature Publishing Group UK London, v. 12, n. 1, p. 7815, 2022.

AL-ELANJAWY, Yasser Abbas Hammady; YILMAZ, Mustafa. Revolutionizing energy: converting co₂ into methanol using flue gases from natural gas combined cycle power plants. **Sustainable Energy & Fuels**, Royal Society of Chemistry, 2025.

ALANAZI, Manar; MAHMOOD, Abdun; CHOWDHURY, Mohammad Javed Morshed. Scada vulnerabilities and attacks: A review of the state-of-the-art and open issues. **Computers & security**, Elsevier, v. 125, p. 103028, 2023.

ALMEIDA, Leandro S de *et al.* Electrochemical devices obtained from biochar: Advances in renewable and environmentally-friendly technologies applied to analytical chemistry. **Trends in Environmental Analytical Chemistry**, Elsevier, v. 26, p. e00089, 2020.

ALVES, Octávio *et al.* Techno-economic study for a gasification plant processing residues of sewage sludge and solid recovered fuels. **Waste Management**, Elsevier, v. 131, p. 148–162, 2021.

ALVES, Octávio *et al.* Market opportunities in portugal for the water-and-waste sector using sludge gasification. **Energies**, MDPI, v. 15, n. 18, p. 6600, 2022.

AMALOU, Ibtissam; MOUHNI, Naoual; ABDALI, Abdelmounaim. Multivariate time series prediction by rnn architectures for energy consumption forecasting. **Energy Reports**, Elsevier, v. 8, p. 1084–1091, 2022.

AMENAGHAWON, Andrew N; ANYALEWECHI, Chinedu L; OKIEIMEN, Charity O; KUSUMA, Heri Septya. Biomass pyrolysis technologies for value-added products: a state-of-the-art review. **Environment, Development and Sustainability**, Springer, p. 1–55, 2021.

ANDOOZ, Amirhossein *et al.* A comprehensive review on pyrolysis from the circular economy point of view and its environmental and social effects. **Journal of Cleaner Production**, Elsevier, v. 388, p. 136021, 2023.

ANIRUDDHA, Ramadurgam; SINGH, Satyapaul A; REDDY, Benjaram M; SREEDHAR, Inkollu. Sorption enhanced reforming: A potential route to produce pure h₂ with in-situ carbon capture. **Fuel**, Elsevier, v. 351, p. 128925, 2023.

ANOKYE, Kwame. From waste to wealth: Exploring biochar's potential in energy generation and waste mitigation. **Cleaner and Circular Bioeconomy**, Elsevier, v. 9, p. 100101, 2024. Disponível em: <<https://doi.org/10.1016/j.clcb.2024.100101>>.

AQUINO, Luiza Scapinello *et al.* Spatiotemporal wind energy forecasting: A comprehensive survey and a deep equilibrium-based case study with StemGNN. **IEEE Access**, v. 13, p. 131461–131482, 2025.

ARIAS, Ana; FEIJOO, Gumersindo; MOREIRA, Maria Teresa. How could artificial intelligence be used to increase the potential of biorefineries in the near future? a review. **Environmental Technology & Innovation**, Elsevier, v. 32, p. 103277, 2023.

ARMAGHANI, Danial Jahed *et al.* An optimized system of GMDH-ANFIS predictive model by ICA for estimating pile bearing capacity. **Artificial Intelligence Review**, Springer, v. 55, p. 2313–2350, 2022.

ASADZADEH, Seyed Mohammad; ANDERSEN, Nils Axel. Optimal operational planning of a bio-fuelled cogeneration plant: Integration of sparse nonlinear dynamics identification and deep reinforcement learning. **Applied Energy**, Elsevier, v. 376, p. 124179, 2024.

ASCHER, Simon; WATSON, Ian; YOU, Siming. Machine learning methods for modelling the gasification and pyrolysis of biomass and waste. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 155, p. 111902, 2022.

ATSONIOS, Konstantinos *et al.* Review on dynamic process modeling of gasification based biorefineries and bio-based heat & power plants. **Fuel Processing Technology**, Elsevier, v. 197, p. 106188, 2020.

AVCI, Onur *et al.* A review of vibration-based damage detection in civil structures: From traditional methods to machine learning and deep learning applications. **Mechanical systems and signal processing**, Elsevier, v. 147, p. 107077, 2021.

AVILÉS, Ana Belén Lozano; VELÁZQUEZ, Francisco del Cerro; RIQUELME, Mercedes Llorens Pascual del. Methodology for energy optimization in wastewater treatment plants. phase i: Control of the best operating conditions. **Sustainability**, MDPI, v. 11, n. 14, p. 3919, 2019.

AWOGBEMI, Omojola; KALLON, Daramy Vandi Von. Application of biochar derived from crops residues for biofuel production. **Fuel Communications**, Elsevier, v. 15, p. 100088, 2023.

AYOL, Azize; YURDAKOS, Ozgun Tezer; GURGEN, Alim. Investigation of municipal sludge gasification potential: Gasification characteristics of dried sludge in a pilot-scale downdraft fixed bed gasifier. **International Journal of Hydrogen Energy**, Elsevier, v. 44, n. 32, p. 17397–17410, 2019.

AYUB, Yousaf; ZHOU, Jianzhao; SHEN, Weifeng; REN, Jingzheng. Innovative valorization of biomass waste through integration of pyrolysis and gasification: Process design, optimization, and multi-scenario sustainability analysis. **Energy**, Elsevier, v. 282, p. 128417, 2023.

BABLER, Matthaus U *et al.* Modeling and pilot plant runs of slow biomass pyrolysis in a rotary kiln. **Applied energy**, Elsevier, v. 207, p. 123–133, 2017.

BAK, Kacper; ZIÓŁKOWSKI, Paweł; FROST, Jacek; DROSIŃSKA-KOMOR, Marta. Comparative study of a combined heat and power plant retrofitted by co2 capture during the combustion of syngas from sewage sludge gasification versus zero-emission combustion of hydrogen produced using renewables. **international journal of hydrogen energy**, Elsevier, v. 48, n. 99, p. 39625–39640, 2023.

BARETH, Rashmi; YADAV, Anamika; GUPTA, Shubhrata; PAZOKI, Mohammad. Daily average load demand forecasting using LSTM model based on historical load trends. **IET Generation, Transmission & Distribution**, v. 18, n. 5, p. 952–962, 2024.

BARSKA, Anetta; JĘDRZEJCZAK-GAS, Janina; WYRWA, Joanna; KONONOWICZ, Krzysztof. Multidimensional assessment of the social development of eu countries in the context of implementing the concept of sustainable development. **Sustainability**, MDPI, v. 12, n. 18, p. 7821, 2020.

BARTZAS, G *et al.* Low carbon certification of agricultural production using field ghg measurements. development of an integrated framework with emphasis on mediterranean products. **Case Studies in Chemical and Environmental Engineering**, Elsevier, v. 9, p. 100666, 2024. Disponível em: <<https://doi.org/10.1016/j.cscee.2024.100666>>.

BATISTA, Ranielly M *et al.* Tools for optimization of biomass-to-energy conversion processes. **Processes**, MDPI, v. 11, n. 3, p. 854, 2023.

BATTISTI, Enrico; BO, Shaocong; PETRUZZELLA, Felice; SALVI, Antonio. Greenwashing and sustainability disclosure in the climate change context: The influence of third-party certification on chinese companies. **Business Strategy and the Environment**, Wiley Online Library, 2025. Disponível em: <<https://doi.org/10.1002/bse.70000>>.

BECKINGHAUSEN, Aubrey *et al.* Post-pyrolysis treatments of biochars from sewage sludge and a. mearnsii for ammonia (nh₄-n) recovery. **Applied Energy**, Elsevier, v. 271, p. 115212, 2020.

BEIK, Farhad; WILLIAMS, Leon; BROWN, Tim; WAGLAND, Stuart T. Development and prototype testing of a novel small-scale pyrolysis system for the treatment of sanitary sludge. **Energy Conversion and Management**, Elsevier, v. 277, p. 116627, 2023.

BENATO, Alberto; BRACCO, Stefano; STOPPATO, Anna; MIRANDOLA, Alberto. Dynamic simulation of combined cycle power plant cycling in the electricity market. **Energy conversion and management**, Elsevier, v. 107, p. 76–85, 2016.

BERGMAN-FONTE, Clarissa *et al.* Repurposing, co-processing and greenhouse gas mitigation—the brazilian refining sector under deep decarbonization scenarios: A case study using integrated assessment modeling. **Energy**, Elsevier, v. 282, p. 128435, 2023.

BERTASINI, Davide *et al.* Decarbonization of the european natural gas grid using hydrogen and methane biologically produced from organic waste: A critical overview. **Renewable Energy**, Elsevier, 2023.

BISINELLA, Valentina *et al.* Environmental assessment of carbon capture and storage (ccs) as a post-treatment technology in waste incineration. **Waste Management**, Elsevier, v. 128, p. 99–113, 2021.

BONG, Hong Kai; SELVARAJOO, Anurita; ARUMUGASAMY, Senthil Kumar. Stability of biochar derived from banana peel through pyrolysis as alternative source of nutrient in soil: feedforward neural network modelling study. **Environmental Monitoring and Assessment**, Springer, v. 194, n. 2, p. 70, 2022.

BORA, Raaj R; RICHARDSON, Ruth E; YOU, Fengqi. Resource recovery and waste-to-energy from wastewater sludge via thermochemical conversion technologies in support of circular economy: a comprehensive review. **BMC Chemical Engineering**, Springer, v. 2, n. 1, p. 8, 2020.

BORRÉ, Andressa *et al.* Machine fault detection using a hybrid CNN-LSTM attention-based model. **Sensors**, v. 23, n. 9, p. 4512, 2023.

BRANCO, Nathielle Waldrigues; CAVALCA, Mariana Santos Matos; OVEJERO, Raúl García. Bootstrap aggregation with christiano–fitzgerald random walk filter for fault prediction in power systems. **Electrical Engineering**, Springer, v. 106, p. 3657–3670, 2024.

BRANCO, Nathielle Waldrigues; CAVALCA, Mariana Santos Matos; STEFENON, Stefano Frizzo; LEITHARDT, Valderi Reis Quietinho. Wavelet LSTM for fault forecasting in electrical power grids. **Sensors**, v. 22, n. 21, p. 8323, 2022.

BRITO, Brunno H *et al.* Exploring symmetry in a short-term hydro scheduling problem: The case of the Santo Antônio hydro plant. **Journal of Water Resources Planning and Management**, American Society of Civil Engineers, v. 148, n. 1, p. 05021026, 2022.

BURATTO, William Gouvêa *et al.* Time series forecasting of thermal systems dispatch in legal amazon using machine learning. **Applied Sciences**, MDPI, v. 14, n. 21, p. 9806, 2024.

BURATTO, William Gouvêa *et al.* Hybrid group method of data handling for time-series forecasting of thermal generation dispatch in electrical power systems. **Electrical Engineering**, Springer, v. 107, n. 10, p. 13929–13945, 2025.

BURATTO, William Gouvêa *et al.* A review of automation and sensors: Parameter control of thermal treatments for electrical power generation. **Sensors**, MDPI, v. 24, n. 3, p. 967, 2024.

BURATTO, William Gouvêa *et al.* Wavelet CNN-LSTM time series forecasting of electricity power generation considering biomass thermal systems. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 18, n. 21, p. 3437–3451, 2024.

BURATTO, William Gouvêa *et al.* Hybrid cf-cnn-bilstm hypertuned by bayesian optimization for thermal power generation and decarbonization forecasting. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 172, p. 111199, 2025.

BUSS, Wolfram *et al.* Mineral-enriched biochar delivers enhanced nutrient recovery and carbon dioxide removal. **Communications Earth & Environment**, Nature Publishing Group UK London, v. 3, n. 1, p. 67, 2022.

CAI, Yingying *et al.* Co2 assisted ca-based additives on pyrolytic characteristics and products from the co-pyrolysis of sewage sludge and biomass. **Separation and Purification Technology**, Elsevier, v. 330, p. 125470, 2024.

CAI, Yingying *et al.* Co2 assisted ca-based additives on pyrolytic characteristics and products from the co-pyrolysis of sewage sludge and biomass. **Separation and Purification Technology**, Elsevier, v. 330, p. 125470, 2024.

CALI, Umit; CATAK, Ferhat Ozgur; HALDEN, Ugur. Trustworthy cyber-physical power systems using ai: dueling algorithms for pmu anomaly detection and cybersecurity. **Artificial Intelligence Review**, Springer, v. 57, n. 7, p. 183, 2024.

CANONICO, Roberto; SPERLÌ, Giancarlo. Industrial cyber-physical systems protection: A methodological review. **Computers & Security**, Elsevier, v. 135, p. 103531, 2023.

CAROTENUTO, Alberto *et al.* Sewage sludge gasification process optimization for combined heat and power generation. **Energies**, MDPI, v. 16, n. 12, p. 4742, 2023.

CECCONET, Daniele; CAPODAGLIO, Andrea G. Sewage sludge biorefinery for circular economy. **Sustainability**, MDPI, v. 14, n. 22, p. 14841, 2022.

CERDA-FLORES, Sandra C; ROJAS-PUNZO, Arturo A; NÁPOLES-RIVERA, Fabricio. Applications of multi-objective optimization to industrial processes: a literature review. **Processes**, MDPI, v. 10, n. 1, p. 133, 2022.

CESARO, Zac *et al.* Ammonia to power: Forecasting the levelized cost of electricity from green ammonia in large-scale power plants. **Applied Energy**, Elsevier, v. 282, p. 116009, 2021.

CHAGAS, Jhon Kenedy Moura; NARDOTO, Gabriela Bielefeld; MADARI, Beata Eموke; FIGUEIREDO, Cícero Célio de. Seven-year effects of sewage sludge biochar on soil organic carbon pools and yield: Understanding the role of biochar on carbon sequestration and productivity. **Soil Use and Management**, Wiley Online Library, v. 40, n. 4, p. e70001, 2024.

CHAI, Yue; PACKHAM, Nicholas; WANG, Meihong. Process improvement analysis of pyrolysis/gasification of biomass and waste plastics with carbon capture and utilisation through process simulation. **Fuel**, Elsevier, v. 324, p. 124571, 2022.

CHALLU, Cristian *et al.* NHITS: Neural hierarchical interpolation for time series forecasting. In: **Proceedings of the AAAI conference on artificial intelligence**. Washington DC, USA: [s.n.], 2023. v. 37, n. 6, p. 6989–6997.

CHANG, Zihan; ZHANG, Yang; CHEN, Wenbo. Electricity price prediction based on hybrid model of adam optimized lstm neural network and wavelet transform. **Energy**, Elsevier, v. 187, p. 115804, 2019.

CHEN, Jinfu *et al.* A novel detection model for abnormal network traffic based on bidirectional temporal convolutional network. **Information and Software Technology**, Elsevier, v. 157, p. 107166, 2023.

CHEN, Junde; YANG, Shuangyuan; ZHANG, Defu; NANEHKARAN, Yaser Ahangari. A turning point prediction method of stock price based on rvfl-gmdh and chaotic time series analysis. **Knowledge and information systems**, Springer, v. 63, n. 10, p. 2693–2718, 2021.

CHEN, Lianhong *et al.* Intelligent modeling of the incineration process in waste incineration power plant based on deep learning. **Energies**, MDPI, v. 15, n. 12, p. 4285, 2022.

CHEN, Yarong; WANG, Xingyan; WANG, Xianyou. Recent advances in biomass waste derived carbon materials for supercapacitors: A review. **Energy Technology**, Wiley Online Library, p. 2301436, 2024.

CHENG, Fangwei; LUO, Hongxi; COLOSI, Lisa M. Slow pyrolysis as a platform for negative emissions technology: An integration of machine learning models, life cycle assessment, and economic analysis. **Energy Conversion and Management**, Elsevier, v. 223, p. 113258, 2020.

CHOI, Ji Yong *et al.* Enhancing the hygrothermal performance of corn cob residue-based eco-friendly building materials through biochar and microencapsulated phase change material incorporation. **Journal of Building Engineering**, Elsevier, v. 89, p. 109189, 2024.

CHU, Xu; FEI, Zixuan; CHU, Zhujie; HUANG, Wei-chiao. Decarbonizing the sludge treatment industry: Assessing the feasibility of achieving carbon reduction from carbon peaking to carbon neutrality. **Journal of Cleaner Production**, Elsevier, p. 140023, 2023.

CHU, Xu; FEI, Zixuan; CHU, Zhujie; HUANG, Wei-chiao. Decarbonizing the sludge treatment industry: Assessing the feasibility of achieving carbon reduction from carbon peaking to carbon neutrality. **Journal of Cleaner Production**, Elsevier, v. 434, p. 140023, 2024.

CHUKWU, Chigozie; VASILEV, Aleksandar; SAHA, Shrabani. Measuring business cycle stylized facts in selected oil-producing economies: A comparative study. **Journal of Business Cycle Research**, Springer, v. 20, n. 1, p. 89–121, 2024.

CLOETE, Schalk *et al.* Zero-cost partial decarbonization of natural gas via molten salt pyrolysis. **International Journal of Hydrogen Energy**, Elsevier, 2023.

COLONETTI, Bruno; FINARDI, Erlon; BRITO, Samuel; ZAVALA, Victor. Parallel dual dynamic integer programming for large-scale hydrothermal unit-commitment. **IEEE Transactions on Power Systems**, v. 38, p. 2926–2938, 2023.

CORSO, M. P. *et al.* Classification of contaminated insulators using k-nearest neighbors based on computer vision. **Computers**, v. 10, n. 9, p. 112, 2021.

CORSO, Marcelo Piccolotto *et al.* Evaluation of visible contamination on power grid insulators using convolutional neural networks. **Electrical Engineering**, Springer, v. 105, p. 3881–3894, 2023.

COSTA, Camila Rodrigues *et al.* Stability and carbon sequestration potential of bamboo biochar. **Biomass Conversion and Biorefinery**, Springer, p. 1–16, 2025.

CROLL, Henry C; IKUMA, Kaoru; ONG, Say Kee; SARKAR, Soumik. Reinforcement learning applied to wastewater treatment process control optimization: Approaches, challenges, and path forward. **Critical Reviews in Environmental Science and Technology**, Taylor & Francis, p. 1–20, 2023.

CULABA, Alvin B *et al.* Design of biorefineries towards carbon neutrality: A critical review. **Bioresource technology**, Elsevier, p. 128256, 2022.

CUONG, Dinh Viet *et al.* A critical review on biochar-based engineered hierarchical porous carbon for capacitive charge storage. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 145, p. 111029, 2021.

DARMAWAN, Arif *et al.* Energy-efficient recovery of black liquor through gasification and syngas chemical looping. **Applied Energy**, Elsevier, v. 219, p. 290–298, 2018.

DAS, Arnob; PEU, Susmita Datta. A comprehensive review on recent advancements in thermochemical processes for clean hydrogen production to decarbonize the energy sector. **Sustainability**, MDPI, v. 14, n. 18, p. 11206, 2022.

DAVOODI, Shadfar *et al.* Review of technological progress in carbon dioxide capture, storage, and utilization. **Gas Science and Engineering**, Elsevier, p. 205070, 2023.

DENG, Huiqi; CHEN, Wenjie; HUANG, Guoru. Deep insight into daily runoff forecasting based on a CNN-LSTM model. **Natural Hazards**, Springer, v. 113, n. 3, p. 1675–1696, 2022.

DENG, Shuanghui *et al.* Characteristics analysis of char from sewage sludge pyrolysis: Char properties, combustion behavior and ash fusion. **Journal of Environmental Chemical Engineering**, Elsevier, v. 13, n. 2, p. 115638, 2025.

DENG, Xu *et al.* Exploring negative emission potential of biochar to achieve carbon neutrality goal in china. **Nature Communications**, Nature Publishing Group UK London, v. 15, n. 1, p. 1085, 2024.

DEON, B *et al.* Digital twin and machine learning for decision support in thermal power plant with combustion engines. **Knowledge-Based Systems**, Elsevier, v. 253, p. 109578, 2022.

DERMÜHL, Sandra; RIEDEL, Uwe. A comparison of the most promising low-carbon hydrogen production technologies. **Fuel**, Elsevier, v. 340, p. 127478, 2023.

DHOKE, Chaitanya; ZAABOUT, Abdelghafour; CLOETE, Schalk; AMINI, Shahriar. Review on reactor configurations for adsorption-based co2 capture. **Industrial & Engineering Chemistry Research**, ACS Publications, v. 60, n. 10, p. 3779–3798, 2021.

DING, Yanming *et al.* Thermal interaction analysis of isolated hemicellulose and cellulose by kinetic parameters during biomass pyrolysis. **Energy**, Elsevier, v. 195, p. 117010, 2020.

DU, Dajun *et al.* A review on cybersecurity analysis, attack detection, and attack defense methods in cyber-physical power systems. **Journal of Modern Power Systems and Clean Energy**, SGEPRI, v. 11, n. 3, p. 727–743, 2022.

DUC, DN; MEEJAROEN, P; NANANUKUL, N. **Multi-objective models for biomass supply chain planning with economic and carbon footprint consideration. Energy Reports**, 7, 6833–6843. 2021.

DUDUKCU, Hatice Vildan; TASKIRAN, Murat; TASKIRAN, Zehra Gulru Cam; YILDIRIM, Tulay. Temporal convolutional networks with rnn approach for chaotic time series prediction. **Applied soft computing**, Elsevier, v. 133, p. 109945, 2023.

DUTRA, Tiago Mota; DIAS, José Carlos; TEIXEIRA, João CA. Measuring financial cycles: empirical evidence for germany, united kingdom and united states of america. **International Review of Economics & Finance**, Elsevier, v. 79, p. 599–630, 2022.

ELIAS, Micah *et al.* Market analysis of coupled biochar and carbon credit production from wildfire fuel reduction projects in the western usa. **Biofuels, Bioproducts and Biorefining**, Wiley Online Library, v. 18, n. 5, p. 1226–1237, 2024. Disponível em: <<https://doi.org/10.1002/bbb.2614>>.

FAHEEM, Muhammad; AL-KHASAWNEH, Mahmoud Ahmad. Multilayer cyberattacks identification and classification using machine learning in internet of blockchain (iobc)-based energy networks. **Data in Brief**, Elsevier, v. 54, p. 110461, 2024.

FAKOYA, Michael Bamidele; IMUEZERUA, Emmanuel O. Identifying ‘true’ water loss information through the mfca model for improved cost-saving decisions in a water utility: A case study of the doorndraai water treatment scheme in south africa. **Sustainability**, MDPI, v. 12, n. 18, p. 7824, 2020.

FANG, Lin *et al.* Biochar-based materials in environmental pollutant elimination, h2 production and co2 capture applications. **Biochar**, Springer, v. 5, n. 1, p. 42, 2023.

FATEMI, Seyed Ehsan; PARVINI, Hosna. The impact assessments of the ACF shape on time series forecasting by the ANFIS model. **Neural Computing and Applications**, Springer, v. 34, n. 15, p. 12723–12736, 2022.

FICHTNER, Florian *et al.* Time-series analysis of sentinel-1/2 data for flood detection using a discrete global grid system and seasonal decomposition. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 119, p. 103329, 2023.

FINKENRATH, Matthias; FABER, Till; BEHRENS, Fabian; LEIPRECHT, Stefan. Holistic modelling and optimisation of thermal load forecasting, heat generation and plant dispatch for a district heating network. **Energy**, Elsevier, v. 250, p. 123666, 2022.

FOZER, Daniel *et al.* Bioenergy with carbon emissions capture and utilisation towards ghg neutrality: Power-to-gas storage via hydrothermal gasification. **Applied Energy**, Elsevier, v. 280, p. 115923, 2020.

FRAIA, Simona Di; MASSAROTTI, Nicola; UDDIN, M Rakib; VANOLI, Laura. Conversion of sewage sludge to combined heat and power: Modeling and optimization. **Smart Energy**, Elsevier, v. 5, p. 100061, 2022.

GARCIA, Irati *et al.* Biomass pyrolysis and in-line air–steam reforming as a potential strategy to progress towards sustainable ammonia production. **Energy Conversion and Management**, Elsevier, v. 304, p. 118221, 2024.

GBASHI, Samuel M; ADEDEJI, Paul A; OLATUNJI, Obafemi O; MADUSHELE, Nkosinathi. Optimal feature selection for a weighted k-nearest neighbors for compound fault classification in wind turbine gearbox. **Results in Engineering**, Elsevier, v. 25, p. 103791, 2025.

GHANBARI-GHALEHJOUGH, Mohsen; TAGHIZAD-TAVANA, Kamran; NOJAVAN, Sayyad. Resilient operation of the renewable energy and battery energy storages based smart distribution grid considering physical-cyber-attacks. **Journal of Energy Storage**, Elsevier, v. 62, p. 106950, 2023.

GHOBAKHLOO, Morteza. Industry 4.0, digitization, and opportunities for sustainability. **Journal of cleaner production**, Elsevier, v. 252, p. 119869, 2020.

GHORBANI, Mohammad *et al.* Feasibility of biochar derived from sewage sludge to promote sustainable agriculture and mitigate ghg emissions—a review. **International journal of environmental research and public health**, MDPI, v. 19, n. 19, p. 12983, 2022. Disponível em: <<https://doi.org/10.3390/ijerph191912983>>.

Gomes e Souza, Henderson; FINARDI, Erlon Cristian; BRITO, Brunno Henrique; TAKIGAWA, Fabrício Yutaka Kuwabata. Partitioning approach based on convex hull and multiple choice for solving hydro unit-commitment problems. **Electric Power Systems Research**, v. 211, p. 108285, 2022. ISSN 0378-7796.

GÓMEZ, Natalia *et al.* Slow pyrolysis of relevant biomasses in the mediterranean basin. part 1. effect of temperature on process performance on a pilot scale. **Journal of cleaner production**, Elsevier, v. 120, p. 181–190, 2016.

GONG, Jianqiang; QU, Zhiguo; ZHU, Zhenle; XU, Hongtao. Parallel timesnet-bilstm model for ultra-short-term photovoltaic power forecasting using stl decomposition and auto-tuning. **Energy**, Elsevier, v. 320, p. 135286, 2025.

GONZÁLEZ, M.; GARCÍA, J.; PÉREZ, L. Thermal hydrolysis of sewage sludge: A case study of a wwtp in burgos, spain. **Applied Sciences**, v. 11, n. 3, p. 964, 2021.

GOUWS, Saartjie M; CARRIER, Marion; BUNT, John Reginald; NEOMAGUS, Hein WJP. Co-pyrolysis of coal and raw/torrefied biomass: A review on chemistry, kinetics and implementation. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 135, p. 110189, 2021.

GUELPA, Elisa; VERDA, Vittorio. Thermal energy storage in district heating and cooling systems: A review. **Applied Energy**, Elsevier, v. 252, p. 113474, 2019.

GUERRA, Roger de T. *et al.* Deep learning approach for automatic heartbeat classification. **Sensors**, v. 25, n. 5, p. 1400, 2025.

GUO, Fei *et al.* Prediction of remaining useful life and state of health of lithium batteries based on time series feature and Savitzky-Golay filter combined with gated recurrent unit neural network. **Energy**, Elsevier, v. 270, p. 126880, 2023.

GUO, Jian-Xin; TAN, Xianchun; GU, Baihe; ZHU, Kaiwei. Integration of supply chain management of hybrid biomass power plant with carbon capture and storage operation. **Renewable Energy**, Elsevier, v. 190, p. 1055–1065, 2022.

GUO, Lili *et al.* Bioenergy market predictions using ai: Integrating climate change and green finance. **Renewable Energy**, Elsevier, p. 123328, 2025.

GUO, Muqian *et al.* Synthesis and electrochemical properties of porous carbon materials from sludge sources. **Circular Economy**, Elsevier, v. 2, n. 4, p. 100064, 2023.

GUO, Shifang *et al.* Recent advances in biochar-based adsorbents for co₂ capture. **Carbon Capture Science & Technology**, Elsevier, v. 4, p. 100059, 2022.

GUO, Tuo; TIAN, Wengang; WANG, Yanxia. Effect of pore structure on co₂ adsorption performance for zncl₂/fecl₃/h₂o (g) co-activated walnut shell-based biochar. **Atmosphere**, MDPI, v. 13, n. 7, p. 1110, 2022.

GUSIATIN, Mariusz Z. Advantages of co-pyrolysis of sewage sludge with agricultural and forestry waste. **Energies**, MDPI, v. 17, n. 22, p. 5736, 2024.

GUSIATIN, Mariusz Z; KULIKOWSKA, Dorota; BERNAT, Katarzyna. Municipal sewage sludge as a resource in the circular economy. **Energies**, MDPI, v. 17, n. 11, p. 2474, 2024. Disponível em: <<https://doi.org/10.3390/en17112474>>.

HABIBI, Mohammad Reza; BAGHAEI, Hamid Reza; BLAABJERG, Frede; DRAGIČEVIĆ, Tomislav. Secure control of dc microgrids for instant detection and mitigation of cyber-attacks based on artificial intelligence. **IEEE Systems Journal**, IEEE, v. 16, n. 2, p. 2580–2591, 2021.

HALALSHEH, M *et al.* Impact of temperature and residence time on sewage sludge pyrolysis for combined carbon sequestration and energy production. **Heliyon**, Elsevier, v. 10, n. 7, 2024.

HANSON, Enobong; NWAKILE, Chukwuebuka; HAMMED, Victor Oluwafolajimi. Carbon capture, utilization, and storage (ccus) technologies: Evaluating the effectiveness of advanced ccus solutions for reducing co₂ emissions. **Results in Surfaces and Interfaces**, Elsevier, v. 18, p. 100381, 2025. Disponível em: <<https://doi.org/10.1016/j.rsurfi.2024.100381>>.

HASSAN, Raouf; BAGHBAN, Alireza. Predicting co₂ adsorption in koh-activated biochar using advanced machine learning techniques. **Scientific Reports**, Nature Publishing Group UK London, v. 15, n. 1, p. 24410, 2025. Disponível em: <<https://doi.org/10.1038/s41598-025-09248-9>>.

HAUGEN, Mari *et al.* On the importance of detailed thermal modeling for price forecasting in hydro-thermal power systems. In: **2019 IEEE Electrical Power and Energy Conference**. Montreal, QC, Canada: IEEE, 2019. p. 1–6.

HE, Debo; YANG, Rui; FU, Yan; ZHU, Bo. Superior properties of biochar contribute to soil carbon sequestration and climate change mitigation. **Journal of Environmental Chemical Engineering**, Elsevier, p. 116936, 2025. Disponível em: <<https://doi.org/10.1016/j.jece.2025.116936>>.

HE, Houtian *et al.* A seasonal-trend decomposition-based dendritic neuron model for financial time series prediction. **Applied Soft Computing**, Elsevier, v. 108, p. 107488, 2021.

HE, Hao *et al.* Wear prediction of YN/Si₃N₄ tribopair lubricated with seawater based on time-series prediction group method of data handling (GMDH) method. **Tribology International**, Elsevier, v. 186, p. 108641, 2023.

HELAL, Md Abu; ANDERSON, Nathaniel; WEI, Yu; THOMPSON, Matthew. A review of biomass-to-bioenergy supply chain research using bibliometric analysis and visualization. **Energies**, MDPI, v. 16, n. 3, p. 1187, 2023.

HEWAGE, Pradeep *et al.* Temporal convolutional neural (tcn) network for an effective weather forecasting using time-series data from the local weather station. **Soft Computing**, Springer, v. 24, p. 16453–16482, 2020.

HOOGWIJK, Monique *et al.* Exploration of the ranges of the global potential of biomass for energy. **Biomass and bioenergy**, Elsevier, v. 25, n. 2, p. 119–133, 2003.

HOSSAIN, Mustafa K *et al.* Influence of pyrolysis temperature on production and nutrient properties of wastewater sludge biochar. **Journal of environmental management**, Elsevier, v. 92, n. 1, p. 223–228, 2011.

HOU, Jiazuo; HU, Chenxi; LEI, Shunbo; HOU, Yunhe. Cyber resilience of power electronics-enabled power systems: A review. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 189, p. 114036, 2024.

HOWARI, Haidar *et al.* Multi-objective optimization for ranking waste biomass materials based on performance and emission parameters in a pyrolysis process—an ahp–topsis approach. **Sustainability**, MDPI, v. 15, n. 4, p. 3690, 2023.

HU, Mian *et al.* A review on turning sewage sludge to value-added energy and materials via thermochemical conversion towards carbon neutrality. **Journal of Cleaner Production**, Elsevier, p. 134657, 2022.

HU, Yusha; ZHOU, Jianzhao; QIAN, Qiming; REN, Jingzheng. Innovative valorization of waste tire by integrating pyrolysis with steam rankine cycle, multi-generation, and desalination: Novel process design, simulation and comprehensive analysis. **Energy**, Elsevier, v. 323, p. 135812, 2025.

HUANG, Carol; MOHAMED, Badr A; LI, Loretta Y. Comparative life-cycle assessment of pyrolysis processes for producing bio-oil, biochar, and activated carbon from sewage sludge. **Resources, Conservation and Recycling**, Elsevier, v. 181, p. 106273, 2022.

HUANG, Carol; MOHAMED, Badr A; LI, Loretta Y. Comparative life-cycle energy and environmental analysis of sewage sludge and biomass co-pyrolysis for biofuel and biochar production. **Chemical Engineering Journal**, Elsevier, v. 457, p. 141284, 2023.

HUANG, Xianling; JI, Ling; YIN, Jianguang; HUANG, Guohe. Optimal design and robust operational management of regional bioethanol supply chain with various technological choices and uncertainty fusions. **Computers & Chemical Engineering**, Elsevier, v. 182, p. 108565, 2024.

HUANG, Yanqin *et al.* Comprehensive competitiveness assessment of four typical municipal sludge treatment routes in china based on environmental and techno-economic analysis. **Science of The Total Environment**, Elsevier, p. 165123, 2023.

IFTIKHAR, Hasnain *et al.* Forecasting day-ahead brent crude oil prices using hybrid combinations of time series models. **Mathematics**, MDPI, v. 11, n. 16, p. 3548, 2023.

ISLAM, KM Nazmul. Municipal solid waste to energy generation: An approach for enhancing climate co-benefits in the urban areas of bangladesh. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 81, p. 2472–2486, 2018.

JANISZEWSKA-LATTERINI, Dominika *et al.* Social awareness as a catalyst for biochar adoption in the agricultural and forestry sectors. **GCB Bioenergy**, Wiley Online Library, v. 17, n. 10, p. e70077, 2025. Disponível em: <<https://doi.org/10.1111/gcbb.70077>>.

JELINEK, Thorsten *et al.* International collaboration: Mainstreaming artificial intelligence and cyberphysical systems for carbon neutrality. **IEEE Transactions on Industrial Cyber-Physical Systems**, IEEE, v. 2, p. 26–34, 2024.

JIANG, Guanyu *et al.* Thermochemical methods for the treatment of municipal sludge. **Journal of Cleaner Production**, Elsevier, v. 311, p. 127811, 2021.

JIANG, G. *et al.* Thermochemical methods for the treatment of municipal sludge. **Journal of Cleaner Production**, v. 311, p. 127811, 2021.

JING, Xiang *et al.* Resilience-oriented planning strategy for the cyber-physical adn under malicious attacks. **Applied Energy**, Elsevier, v. 353, p. 122052, 2024.

JUUSO, Kivijakola *et al.* A sustainable business ecosystem: a case study demonstrating biochar's potential. **Biofuels, Bioproducts and Biorefining**, Wiley Online Library, 2025. Disponível em: <<https://doi.org/10.1002/bbb.70007>>.

KABUGO, James Clovis; JÄMSÄ-JOUNELA, Sirkka-Liisa; SCHIEMANN, Robert; BINDER, Christian. Industry 4.0 based process data analytics platform: A waste-to-energy plant case study. **International journal of electrical power & energy systems**, Elsevier, v. 115, p. 105508, 2020.

KADAM, Parag; DWIVEDI, Puneet; MARRERO, Thomas W. Biochar economics for private landowners with payments from carbon markets and federal incentives. **GCB Bioenergy**, Wiley Online Library, v. 17, n. 9, p. e70065, 2025. Disponível em: <<https://doi.org/10.1111/gcbb.70065>>.

KAHWASH, F.; BARAKAT, B.; MAHERI, A. Coupled thermo-electrical dispatch strategy with ai forecasting for optimal sizing of grid-connected hybrid renewable energy systems. **Energy Conversion and Management**, v. 293, p. 117460, 2023. ISSN 0196-8904.

KAN, Tao; STREZOV, Vladimir; EVANS, Tim J. Lignocellulosic biomass pyrolysis: A review of product properties and effects of pyrolysis parameters. **Renewable and sustainable energy reviews**, Elsevier, v. 57, p. 1126–1140, 2016.

Kasburg, C.; Stefenon, S. F. Deep learning for photovoltaic generation forecast in active solar trackers. **IEEE Latin America Transactions**, v. 17, n. 12, p. 2013–2019, 2019.

KASBURG, Christopher; STEFENON, Stéfano Frizzo. Deep learning for photovoltaic generation forecast in active solar trackers. **IEEE Latin America Transactions**, v. 17, n. 12, p. 2013–2019, 2019.

KAUR, Ramanpreet; GABRIJELČIČ, Dušan; KLOBUČAR, Tomaž. Artificial intelligence for cybersecurity: Literature review and future research directions. **Information Fusion**, Elsevier, v. 97, p. 101804, 2023.

KELLER, Florian; VOSS, Raoul Lukas; LEE, Roh Pin; MEYER, Bernd. Life cycle assessment of global warming potential of feedstock recycling technologies: Case study of waste gasification and pyrolysis in an integrated inventory model for waste treatment and chemical production in germany. **Resources, Conservation and Recycling**, Elsevier, v. 179, p. 106106, 2022.

KETOV, Aleksandr *et al.* Plant biomass conversion to vehicle liquid fuel as a path to sustainability. **Resources**, MDPI, v. 11, n. 8, p. 75, 2022.

KHAMLICH, Imane *et al.* Technical and economic assessment of thermal energy storage in concentrated solar power plants within a spot electricity market. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 139, p. 110583, 2021.

KHAN, Muhammed Zafar Ali *et al.* Potential of clean liquid fuels in decarbonizing transportation—an overlooked net-zero pathway? **Renewable and Sustainable Energy Reviews**, Elsevier, v. 183, p. 113483, 2023.

KHAN, Ramsha *et al.* Sewage sludge derived biochar and its potential for sustainable environment in circular economy: Advantages and challenges. **Chemical Engineering Journal**, Elsevier, p. 144495, 2023.

KHAN, Usman *et al.* Hydrogen from sewage sludge: Production methods, influencing factors, challenges, and prospects. **Science of The Total Environment**, Elsevier, p. 170696, 2024.

KIJO-KLECZKOWSKA, Agnieszka *et al.* Experimental research and prediction of heat generation during plastics, coal and biomass waste combustion using thermal analysis methods. **Energy**, Elsevier, v. 290, p. 130168, 2024.

KIM, Junhong; MOON, Jihoon; HWANG, Eenjun; KANG, Pilsung. Recurrent inception convolution neural network for multi short-term load forecasting. **Energy and buildings**, Elsevier, v. 194, p. 328–341, 2019.

KLAAR, Anne Carolina Rodrigues *et al.* Optimized EWT-Seq2Seq-LSTM with attention mechanism to insulators fault prediction. **Sensors**, MDPI, v. 23, n. 6, p. 3202, 2023.

KLAAR, Anne Carolina Rodrigues *et al.* Structure optimization of ensemble learning methods and seasonal decomposition approaches to energy price forecasting in Latin America: A case study about Mexico. **Energies**, MDPI, v. 16, n. 7, p. 3184, 2023.

KOSTOWSKI, Wojciech *et al.* Generation of renewable hydrogen from sewage sludge—quantitative and energy-based technology evaluation. **International Journal of Hydrogen Energy**, Elsevier, v. 52, p. 983–994, 2024.

KREIBICH, Nicolas. Toward global net zero: the voluntary carbon market on its quest to find its place in the post-paris climate regime. **Wiley Interdisciplinary Reviews: Climate Change**, Wiley Online Library, v. 15, n. 5, p. e892, 2024. Disponível em: <<https://doi.org/10.1002/wcc.892>>.

KRISHNAN, Anjana; NIGHOJKAR, Amrita; KANDASUBRAMANIAN, Balasubramanian. Emerging towards zero carbon footprint via carbon dioxide capturing and sequestration. **Carbon Capture Science & Technology**, Elsevier, p. 100137, 2023.

KROCHMALNY, Krystian *et al.* Determination of the marker for automation of torrefaction and slow pyrolysis processes—a case study of spherical wood particles. **Renewable Energy**, Elsevier, v. 161, p. 350–360, 2020.

KUFENKO, Vadim. Hide-and-peek with time-series filters: A model-based monte carlo study. **Empirical Economics**, Springer, v. 59, p. 2335–2361, 2020.

KUMAR, Naveen; LEE, Seul Chan. Human-machine interface in smart factory: A systematic literature review. **Technological Forecasting and Social Change**, Elsevier, v. 174, p. 121284, 2022.

KWON, Ki-Seok; LEE, Han-Seung. Sustainable development of sawdust biochar as a green and promising material for co2 capture technologies. **Materials**, MDPI, v. 18, n. 14, p. 3243, 2025.

La Picirelli de Souza, Lidiane *et al.* Life cycle assessment of prospective scenarios maximizing renewable resources in the brazilian electricity matrix. **Renewable Energy Focus**, v. 44, p. 1–18, 2023. ISSN 1755-0084.

LARCHER, Jos'e Henrique Klein"ubing; STEFENON, Stefano Frizzo; COELHO, Leandro dos Santos; MARIANI, Viviana Cocco. Enhanced multi-step streamflow series forecasting using hybrid signal decomposition and optimized reservoir computing models. **Expert Systems with Applications**, Elsevier, p. 124856, 2024.

LARROYD, Paulo Vitor *et al.* Dealing with negative inflows in the long-term hydrothermal scheduling problem. **Energies**, v. 15, n. 3, 2022. ISSN 1996-1073.

LAYEK, Jayanta *et al.* Prospects of biochar for sustainable agriculture and carbon sequestration: an overview for eastern himalayas. **Sustainability**, MDPI, v. 14, n. 11, p. 6684, 2022. Disponível em: <<https://doi.org/10.3390/su14116684>>.

LEDMAOUI, Younes; MAGHRAOUI, Adila El; AROUSSI, Mohamed El; SAADANE, Rachid. Review of recent advances in predictive maintenance and cybersecurity for solar plants. **Sensors**, MDPI, v. 25, n. 1, p. 206, 2025.

LEDÓN, Yannay Casas *et al.* Exergoeconomic valuation of a waste-based integrated combined cycle (wicc) for heat and power production. **Energy**, Elsevier, v. 114, p. 239–252, 2016.

LEE, Hyojin; CHOI, Il-Ho; HWANG, Kyung-Ran. Machine learning prediction of bio-oil production from the pyrolysis of lignocellulosic biomass: Recent advances and future perspectives. **Journal of Analytical and Applied Pyrolysis**, Elsevier, p. 106486, 2024.

LEEuw, M De; KOELEMEIJER, R. **Decarbonisation options for the Dutch waste incineration industry**. [S.l.]: PBL and TNO, 2022.

LEI, Lei *et al.* Dynamic energy dispatch based on deep reinforcement learning in iot-driven smart isolated microgrids. **IEEE internet of things journal**, IEEE, v. 8, n. 10, p. 7938–7953, 2020.

LEI, Shunbo *et al.* Power economic dispatch against extreme weather conditions: The price of resilience. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 157, p. 111994, 2022.

LI, Congcong *et al.* Hydrological response to climate and land use changes in the dry-warm valley of the upper yangtze river. **Engineering**, Elsevier, v. 19, p. 24–39, 2022.

LI, Hui *et al.* A review on migration and transformation of nitrogen during sewage sludge thermochemical treatment: Focusing on pyrolysis, gasification and combustion. **Fuel Processing Technology**, Elsevier, v. 240, p. 107562, 2023.

LI, Jie; LI, Lanyu; TONG, Yen Wah; WANG, Xiaonan. Understanding and optimizing the gasification of biomass waste with machine learning. **Green Chemical Engineering**, Elsevier, v. 4, n. 1, p. 123–133, 2023.

LI, Jinghua; LUO, Yichen; WEI, Shanyang. Long-term electricity consumption forecasting method based on system dynamics under the carbon-neutral target. **Energy**, Elsevier, v. 244, p. 122572, 2022.

LI, Liping *et al.* Carbon footprint analysis of sewage sludge thermochemical conversion technologies. **Sustainability**, MDPI, v. 15, n. 5, p. 4170, 2023.

LI, Ming; ZHAO, Wei. Environmental impact of anaerobic digestion of sludge. **Journal of Cleaner Production**, v. 245, p. 118857, 2020.

LI, Simeng; TASNADY, Desarae. Biochar for soil carbon sequestration: Current knowledge, mechanisms, and future perspectives. **C**, MDPI, v. 9, n. 3, p. 67, 2023.

LI, Ying *et al.* Study on the potential of sludge-derived humic acid as energy storage material. **Waste Management**, Elsevier, v. 162, p. 55–62, 2023.

LI, Yiyang *et al.* A tcn-based hybrid forecasting framework for hours-ahead utility-scale pv forecasting. **IEEE Transactions on Smart Grid**, v. 14, n. 5, p. 4073–4085, 2023.

LI, Yang; ZHANG, Shitu; LI, Yuanzheng. Ai-enhanced resilience in power systems: Adversarial deep learning for robust short-term voltage stability assessment under cyber-attacks. **Chaos, Solitons & Fractals**, Elsevier, v. 196, p. 116406, 2025.

LIEW, Chin-Seng *et al.* Stabilization of heavy metals loaded sewage sludge: Reviewing conventional to state-of-the-art thermal treatments in achieving energy sustainability. **Chemosphere**, Elsevier, v. 277, p. 130310, 2021.

LIM, Bryan; ARIK, Sercan Ö; LOEFF, Nicolas; PFISTER, Tomas. Temporal fusion transformers for interpretable multi-horizon time series forecasting. **International Journal of Forecasting**, Elsevier, v. 37, n. 4, p. 1748–1764, 2021.

LIN, Gang *et al.* Review on the key technologies of power grid cyber-physical systems simulation. **IET Cyber-Physical Systems: Theory & Applications**, Wiley Online Library, v. 9, n. 1, p. 1–16, 2024.

LIN, Guiying *et al.* Enhancing agricultural productivity with biochar: Evaluating feedstock and quality standards. **Bioresource Technology Reports**, Elsevier, v. 29, p. 102059, 2025. Disponível em: <<https://doi.org/10.1016/j.biteb.2025.102059>>.

LIN, Junhao *et al.* Scaled-up microwave pyrolysis of sludge for hydrogen-rich biogas and life cycle assessment: Parameters synergistic optimization, carbon footprint analysis and technology upgrade. **Chemical Engineering Journal**, Elsevier, v. 452, p. 139551, 2023.

LIN, Yu *et al.* Controllable preparation of green biochar based high-performance supercapacitors. **Ionics**, Springer, v. 28, n. 6, p. 2525–2561, 2022.

LINDAUER, Marius *et al.* Smac3: A versatile bayesian optimization package for hyperparameter optimization. **Journal of Machine Learning Research**, v. 23, n. 54, p. 1–9, 2022.

LIU, Bingchun; FU, Yi; XIAOQIN, Liang; FENG, Zijie. Electricity generation potential forecast of beijing municipal solid waste separation rate based on gra-bilstm model. **Waste and Biomass Valorization**, Springer, v. 15, n. 7, p. 3969–3986, 2024.

LIU, Bingchun; ZHENG, Shize; LAI, Mingzhao. Carbon emission reduction potential analysis of fuel cell vehicles in china: based on gra-bilstm prediction model. **International Journal of Hydrogen Energy**, Elsevier, v. 66, p. 110–121, 2024.

LIU, Chang *et al.* Co2 capture using biochar derived from conditioned sludge via pyrolysis. **Separation and Purification Technology**, Elsevier, v. 314, p. 123624, 2023.

LIU, Cheng *et al.* Long-term observations of atmospheric constituents at the first ground-based high-resolution fourier-transform spectrometry observation station in china. **Engineering**, Elsevier, v. 22, p. 201–214, 2023.

LIU, Enbin; LU, Xudong; WANG, Daocheng. A systematic review of carbon capture, utilization and storage: status, progress and challenges. **Energies**, MDPI, v. 16, n. 6, p. 2865, 2023.

LIU, Huachen; LU, Hao; HU, Heng. Co2 capture and mineral storage: State of the art and future challenges. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 189, p. 113908, 2024.

LIU, Hui; YANG, Rui; DUAN, Zhu; WU, Haiping. A hybrid neural network model for marine dissolved oxygen concentrations time-series forecasting based on multi-factor analysis and a multi-model ensemble. **Engineering**, Elsevier, v. 7, n. 12, p. 1751–1765, 2021.

LIU, Jun *et al.* Evaluation and improvements on the flexibility and economic performance of a thermal power plant while applying carbon capture, utilization & storage. **Energy Conversion and Management**, Elsevier, v. 290, p. 117219, 2023.

LIU, Jun *et al.* A new approach to co2 capture and sequestration: A novel carbon capture artificial aggregates made from biochar and municipal waste incineration bottom ash. **Construction and Building Materials**, Elsevier, v. 398, p. 132472, 2023.

LIU, Jun *et al.* Direct air capture of co2 using biochar prepared from sewage sludge: Adsorption capacity and kinetics. **Science of The Total Environment**, Elsevier, v. 948, p. 174887, 2024.

LIU, Jun *et al.* Exploring the carbon capture and sequestration performance of biochar-artificial aggregate using a new method. **Science of The Total Environment**, Elsevier, v. 859, p. 160423, 2023.

LIU, Wei; LIU, Qian; LI, Yulin. Ultra-short-term photovoltaic power prediction based on modal reconstruction and bilstm-cnn-attention model. **Earth Science Informatics**, Springer, v. 17, n. 3, p. 2711–2725, 2024.

LIVIERIS, Ioannis E; PINTELAS, Emmanuel; PINTELAS, Panagiotis. A CNN-LSTM model for gold price time-series forecasting. **Neural computing and applications**, Springer, v. 32, p. 17351–17360, 2020.

LONG, Yilin *et al.* Low-carbon economic dispatch considering integrated demand response and multistep carbon trading for multi-energy microgrid. **Scientific reports**, Nature Publishing Group UK London, v. 12, n. 1, p. 6218, 2022.

LU, Chaoyang *et al.* An automated control system for pilot-scale biohydrogen production: design, operation and validation. **International Journal of Hydrogen Energy**, Elsevier, v. 45, n. 6, p. 3795–3806, 2020.

LU, Jiantao; JIA, Bin; LI, Shunming; GONG, Siqi. A noise reduction method of rolling bearing based on empirical wavelet transform and adaptive time frequency peak filtering. **Measurement Science and Technology**, IOP Publishing, v. 34, n. 12, p. 125146, 2023.

LU, Wenjie; LI, Jiazheng; WANG, Jingyang; QIN, Lele. A cnn-bilstm-am method for stock price prediction. **Neural Computing and Applications**, Springer, v. 33, n. 10, p. 4741–4753, 2021.

LUO, Juan *et al.* Bio-fuels generation and the heat conversion mechanisms in different microwave pyrolysis modes of sludge. **Applied energy**, Elsevier, v. 266, p. 114855, 2020.

MAGNE, Angelica; KHATIWADA, Dilip; CARDOZO, Evelyn. Assessing the bioenergy potential in south america: Projections for 2050. **Energy for Sustainable Development**, Elsevier, v. 82, p. 101535, 2024.

MAHMOUD, Amal; MOHAMMED, Ammar. A survey on deep learning for time-series forecasting. **Machine learning and big data analytics paradigms: analysis, applications and challenges**, Springer, p. 365–392, 2021.

MAKTABIFARD, Mojtaba *et al.* Net-zero carbon condition in wastewater treatment plants: A systematic review of mitigation strategies and challenges. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 185, p. 113638, 2023.

MALODE, Shweta J *et al.* Biomass-derived carbon nanomaterials for sensor applications. **Journal of Pharmaceutical and Biomedical Analysis**, Elsevier, v. 222, p. 115102, 2023.

MAN, Yuanyuan *et al.* Enhanced LSTM model for daily runoff prediction in the upper Huai river basin, China. **Engineering**, Elsevier, v. 24, p. 229–238, 2023.

MANASA, Pantrangi; SAMBASIVAM, Sangaraju; RAN, Fen. Recent progress on biomass waste derived activated carbon electrode materials for supercapacitors applications—a review. **Journal of Energy Storage**, Elsevier, v. 54, p. 105290, 2022.

MARTINHO, Vítor Domingues; MOURÃO, Paulo Reis. Circular economy and economic development in the european union: A review and bibliometric analysis. **Sustainability**, MDPI, v. 12, n. 18, p. 7767, 2020.

MATARRU, Andre Amba; SHIN, Donghoon. Biochar production technology as a negative emission strategy: A review. **Energies**, MDPI, v. 18, n. 18, p. 4898, 2025. Disponível em: <<https://doi.org/10.3390/en18184898>>.

MAZARE, Mahmood; RAMEZANI, Hossein. Enhancing cybersecurity in wind turbines: A resilient reinforcement learning-based optimal control for mitigating fdi attacks. **Applied Energy**, Elsevier, v. 373, p. 123939, 2024.

MEDEIROS, A. *et al.* Comparison of artificial intelligence techniques to failure prediction in contaminated insulators based on leakage current. **Journal of Intelligent & Fuzzy Systems**, v. 42, n. 4, p. 3285–3298, 2022.

MIAN, Md Manik *et al.* Emerging applications of sludge biochar-based catalysts for environmental remediation and energy storage: A review. **Journal of Cleaner Production**, Elsevier, v. 360, p. 132131, 2022.

MICHAGA, Maria Fernanda Rojas *et al.* Bioenergy with carbon capture and storage (beccs) potential in jet fuel production from forestry residues: A combined techno-economic and life cycle assessment approach. **Energy Conversion and Management**, Elsevier, v. 255, p. 115346, 2022.

MIHOUB, Alaeddine *et al.* Denial of service attack detection and mitigation for internet of things using looking-back-enabled machine learning techniques. **Computers & Electrical Engineering**, Elsevier, v. 98, p. 107716, 2022.

MIRICIOIU, Marius Gheorghe *et al.* Sewage sludge derived materials for co₂ adsorption. **Applied Sciences**, MDPI, v. 11, n. 15, p. 7139, 2021. Disponível em: <<https://doi.org/10.3390/app11157139>>.

MISHRA, Sakshi; KWASNIK, Ted; ANDERSON, Kate. Microgrid resilience: A holistic and context-aware resilience metric. **Energy Systems**, Springer, v. 14, n. 4, p. 1081–1105, 2023.

MOHAMMADPOURFARD, Mostafa *et al.* Cyber-physical attack conduction and detection in decentralized power systems. **IEEE Access**, IEEE, v. 10, p. 29277–29286, 2022.

MOLES, Samuel *et al.* Pilot-scale study of sorption-enhanced gasification of sewage sludge. **Fuel**, Elsevier, v. 360, p. 130611, 2024.

MONFORT, M Domènech *et al.* Energy system transformations toward zero emissions: A focus on pyrolysis. **Energy Conversion and Management: X**, Elsevier, p. 101052, 2025.

MONTAGNARO, Fabio *et al.* Modelling oxy-pyrolysis of sewage sludge in a rotary kiln reactor. **Fuel**, Elsevier, v. 231, p. 468–478, 2018.

MORENO, Sinvaldo Rodrigues *et al.* Enhancing wind speed forecasting through synergy of machine learning, singular spectral analysis, and variational mode decomposition. **Energy**, v. 292, p. 130493, 2024.

MORGANO, M. Tomasi *et al.* An overview of the thermochemical valorization of sewage sludge: Principles and current challenges. **Energies**, MDPI, v. 17, n. 10, p. 2417, 2024.

MOSSO, Daniele *et al.* How much do carbon emission reduction strategies comply with a sustainable development of the power sector? **Energy Reports**, Elsevier, v. 11, p. 3064–3087, 2024.

MOTLAGH, Naser Hossein; MOHAMMADREZAEI, Mahsa; HUNT, Julian; ZAKERI, Behnam. Internet of things (iot) and the energy sector. **Energies**, MDPI, v. 13, n. 2, p. 494, 2020.

MOTTA, Ronaldo Seroa da. Carbon markets and the financing of forestry, agricultural, and livestock activities. **Sustainability Challenges of Brazilian Agriculture: Governance, Inclusion, and Innovation**, Springer, p. 107–121, 2023. Disponível em: <https://doi.org/10.1007/978-3-031-29853-0_6>.

MUNIZ, Rafael Ninno *et al.* State-of-the-art decarbonization in sludge thermal treatments for electrical power generation considering sensors and the application of artificial intelligence. **Water**, MDPI, v. 17, n. 13, p. 1946, 2025. Disponível em: <<https://doi.org/10.3390/w17131946>>.

MUNIZ, Rafael Ninno *et al.* The sustainability concept: A review focusing on energy. **Sustainability**, MDPI, v. 15, n. 19, p. 14049, 2023.

MUNIZ, Rafael Ninno *et al.* Tools for measuring energy sustainability: A comparative review. **Energies**, MDPI, v. 13, n. 9, p. 2366, 2020.

NACHENIUS, Robert W; RONSSE, Frederik; VENDERBOSCH, RH; PRINS, Wolter. Biomass pyrolysis. In: **Advances in chemical engineering**. [S.l.]: Elsevier, 2013. v. 42, p. 75–139.

NANDHINI, Rajendran *et al.* Thermochemical conversion of municipal solid waste into energy and hydrogen: a review. **Environmental Chemistry Letters**, Springer, v. 20, n. 3, p. 1645–1669, 2022.

NANDHINI, Rajendran; SIVAPRAKASH, Baskaran; RAJAMOCHAN, Natarajan; VO, Dai-Viet N. Carbon-free hydrogen and bioenergy production through integrated carbon capture and storage technology for achieving sustainable and circular economy—a review. **Fuel**, Elsevier, v. 342, p. 126984, 2023.

NANDITHA, J.S.; MISHRA, Vimal. On the need of ensemble flood forecast in india. **Water Security**, v. 12, p. 100086, 2021. ISSN 2468-3124.

NAQVI, Salman Raza *et al.* Applications of machine learning in thermochemical conversion of biomass—a review. **Fuel**, Elsevier, v. 332, p. 126055, 2023.

NASCIMENTO, Marisa; SOARES, Paulo Sergio Moreira. Potential impact of coal mining and use for electricity generation in brazil on global warming. **Journal of Sustainable Mining**, Central Mining Institute, v. 24, n. 1, p. 65–75, 2025.

NASIR, Amirah Syafika Mohd; MOHAMED, Badr; LI, Loretta Y. Comparative life cycle assessment of co-pyrolysing sewage sludge and wastewater-grown microalgae for biofuel production. **Resources, Conservation and Recycling**, Elsevier, v. 190, p. 106780, 2023.

NAVARRO, África *et al.* The role of biogenic waste composition on pyrolysis: Part ii—char co₂ adsorption capacity. **Biomass and Bioenergy**, Elsevier, v. 197, p. 107775, 2025. Disponível em: <<https://doi.org/10.1016/j.biombioe.2025.107775>>.

NAZIR, Amril *et al.* Enhancing energy consumption forecasting for electric vehicle charging stations with time series dense encoder (tide). **e-Prime-Advances in Electrical Engineering, Electronics and Energy**, Elsevier, p. 100997, 2025.

NAZIR, Amril; SHAIKH, Abdul Khalique; SHAH, Abdul Salam; KHALIL, Ashraf. Forecasting energy consumption demand of customers in smart grid using temporal fusion transformer (tft). **Results in Engineering**, Elsevier, v. 17, p. 100888, 2023.

NEJAD, Seyed Mahdi Mirhoseini *et al.* Multispectral crop yield prediction using 3d-convolutional neural networks and attention convolutional lstm approaches. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 16, p. 254–266, 2022.

NEOGI, Suvadip *et al.* Sustainable biochar: A facile strategy for soil and environmental restoration, energy generation, mitigation of global climate change and circular bioeconomy. **Chemosphere**, Elsevier, v. 293, p. 133474, 2022. Disponível em: <<https://doi.org/10.1016/j.chemosphere.2021.133474>>.

NETO, N. F. Sopelsa *et al.* Fault prediction based on leakage current in contaminated insulators using enhanced time series forecasting models. **Sensors**, v. 22, n. 16, p. 6121, 2022.

OFUANI, Nnamdi; BHOI, Prakashbhai. Carbon dioxide gasification of biochar: a sustainable way of utilizing captured co2 to mitigate greenhouse gas emission. **Sustainability**, MDPI, v. 16, n. 12, p. 5044, 2024. Disponível em: <<https://doi.org/10.3390/su16125044>>.

OKONKWO, Eric C; ALNOUSS, Ahmed; SHAHBAZ, Muhammad; AL-ANSARI, Tareq. Developing integrated direct air capture and bioenergy with carbon capture and storage systems: progress towards 2° c and 1.5° c climate goals. **Energy Conversion and Management**, Elsevier, v. 296, p. 117687, 2023.

OKTAVIANA, Ade Ayu; HERMANA, Joni; SYAFEI, Arie Dipareza; HSI, Hsing Cheng. Effect of pyrolysis temperature of domestic sewage sludge biochar on co2 adsorption. **Results in Engineering**, Elsevier, p. 105136, 2025.

OLAFASAKIN, Olumide *et al.* Machine learning reduced order model for cost and emission assessment of a pyrolysis system. **Energy & Fuels**, ACS Publications, v. 35, n. 12, p. 9950–9960, 2021.

OLIVARES, Kin G. *et al.* Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with nbeatsx. **International Journal of Forecasting**, v. 39, n. 2, p. 884–900, 2023. ISSN 0169-2070.

OLIVEIRA, Aline Kirsten Vidal de *et al.* Assessing the potential of green hydrogen in decarbonizing off-grid amazonian communities. In: IEEE. **2023 International Conference on Future Energy Solutions (FES)**. [S.l.], 2023. p. 1–6.

OLMO, Félix Hernández-del *et al.* Advanced control by reinforcement learning for wastewater treatment plants: A comparison with traditional approaches. **Applied Sciences**, MDPI, v. 13, n. 8, p. 4752, 2023.

ORESHKIN, Boris N; DUDEK, Grzegorz; PEŁKA, Paweł; TURKINA, Ekaterina. N-beats neural network for mid-term electricity load forecasting. **Applied Energy**, Elsevier, v. 293, p. 116918, 2021.

OSMAN, Ahmed I *et al.* Optimizing biomass pathways to bioenergy and biochar application in electricity generation, biodiesel production, and biohydrogen production. **Environmental Chemistry Letters**, Springer, v. 21, n. 5, p. 2639–2705, 2023.

OYUCU, Saadin *et al.* Ensemble learning framework for ddos detection in sdn-based scada systems. **Sensors**, MDPI, v. 24, n. 1, p. 155, 2023.

PAPADIS, Elisa; TSATSARONIS, George. Challenges in the decarbonization of the energy sector. **Energy**, Elsevier, v. 205, p. 118025, 2020.

PATEL, Maga Ram; PANWAR, Narayan Lal. Development, process optimization and assessment of sustainable mobile biochar kiln for agricultural use. **Journal of Cleaner Production**, Elsevier, v. 477, p. 143866, 2024. Disponível em: <<https://doi.org/10.1016/j.jclepro.2024.143866>>.

PEDRINI, Renata; BELTRÁN, Felipe; FINARDI, Erlon C. Innovative approaches to stochastic dual dynamic programming: Two-period decomposition and parallelization in a hydrothermal scheduling case study. **Journal of Water Resources Planning and Management**, American Society of Civil Engineers, v. 150, n. 12, p. 05024014, 2024.

PELTOLA, Petteri *et al.* A novel dual circulating fluidized bed technology for thermal treatment of municipal sewage sludge with recovery of nutrients and energy. **Waste Management**, Elsevier, v. 155, p. 329–337, 2023.

PETERSEN, Henrik I; SANEI, Hamed. The h/c molar ratio and its potential pitfalls for determining biochar's permanence. **GCB Bioenergy**, Wiley Online Library, v. 17, n. 6, p. e70049, 2025. Disponível em: <<https://doi.org/10.1111/gcbb.70049>>.

PEU, Susmita Datta *et al.* A comprehensive review on recent advancements in absorption-based post combustion carbon capture technologies to obtain a sustainable energy sector with clean environment. **Sustainability**, MDPI, v. 15, n. 7, p. 5827, 2023.

PIERSON, Derek *et al.* Beyond the basics: a perspective on barriers and opportunities for scaling up biochar production from forest slash. **Biochar**, Springer, v. 6, n. 1, p. 1, 2024. Disponível em: <<https://doi.org/10.1007/s42773-023-00290-2>>.

PLESHIVTSEVA, Yuliya; DEREVYANOV, Maksim; PIMENOV, Andrey; RAPOPORT, Alexey. Comparative analysis of global trends in low carbon hydrogen production towards the decarbonization pathway. **International Journal of Hydrogen Energy**, Elsevier, 2023.

POPP, József *et al.* Bioeconomy: Biomass and biomass-based energy supply and demand. **New biotechnology**, Elsevier, v. 60, p. 76–84, 2021.

PUSTY, Kasturi *et al.* Ultrasound assisted phytochemical extraction of red cabbage by using deep eutectic solvent: Modelling using anfis and optimization by genetic algorithms. **Ultrasonics Sonochemistry**, Elsevier, v. 102, p. 106762, 2024.

QAMAR, Obaid Ali *et al.* Feasibility-to-applications of value-added products from biomass: Current trends, challenges, and prospects. **Chemical Engineering Journal**, Elsevier, v. 454, p. 140240, 2023.

QIAN, Lili *et al.* Supercritical water gasification and partial oxidation of municipal sewage sludge: An experimental and thermodynamic study. **International Journal of Hydrogen Energy**, Elsevier, v. 46, n. 1, p. 89–99, 2021.

QUAN, Cui *et al.* Direct co₂ capture from air using char from pyrolysis of digestate solid. **Biomass and Bioenergy**, Elsevier, v. 175, p. 106891, 2023.

QUAN, Cui *et al.* Biomass-based carbon materials for co₂ capture: A review. **Journal of CO₂ Utilization**, Elsevier, v. 68, p. 102373, 2023.

QUEIROZ, Humberto; LOPES, Rui Amaral; MARTINS, João. Automated energy storage and curtailment system to mitigate distribution transformer aging due to high renewable energy penetration. **Electric Power Systems Research**, Elsevier, v. 182, p. 106199, 2020.

RAHMAN, Md Mijanur *et al.* Prospective methodologies in hybrid renewable energy systems for energy prediction using artificial neural networks. **Sustainability**, MDPI, v. 13, n. 4, p. 2393, 2021.

RANGAPURAM, Syama Sundar *et al.* Deep non-parametric time series forecaster. **arXiv**, v. 1, p. 1–12, 2023. Disponível em: <<https://arxiv.org/abs/2312.14657>>.

RAWAT, Shivam *et al.* Sustainable biochar for advanced electrochemical/energy storage applications. **Journal of Energy Storage**, Elsevier, v. 63, p. 107115, 2023.

RAZA, Mohsin *et al.* Progress of the pyrolyzer reactors and advanced technologies for biomass pyrolysis processing. **Sustainability**, MDPI, v. 13, n. 19, p. 11061, 2021.

RAZA, Saleem *et al.* Engineering approaches for co₂ converting to biomass coupled with nanobiomaterials as biomediated towards circular bioeconomy. **Journal of CO₂ Utilization**, Elsevier, v. 67, p. 102295, 2023.

REKERAHO, Alexandre *et al.* Cybersecurity challenges in iot-based smart renewable energy. **International Journal of Information Security**, Springer, v. 23, n. 1, p. 101–117, 2024.

REN, Haixi; KONG, Fanlong; ZHENG, Hao; JIANG, Zhixiang. Exploring the preferred technology for sewage sludge treatment in china based on an integrated method of life cycle assessment and monetization model. **Journal of Cleaner Production**, Elsevier, p. 145689, 2025.

REZA, Md Sumon *et al.* Advanced applications of carbonaceous materials in sustainable water treatment, energy storage, and co₂ capture: a comprehensive review. **Sustainability**, MDPI, v. 15, n. 11, p. 8815, 2023.

REZAEI, Masoud; SAMETI, Mohammad; NASIRI, Fuzhan. An enviro-economic ram-based optimization of biomass-driven combined heat and power generation. **Biomass Conversion and Biorefinery**, Springer, p. 1–16, 2023.

RIBEIRO, Matheus Henrique Dal Molin *et al.* Decoding electroencephalography signal response by stacking ensemble learning and adaptive differential evolution. **Sensors**, v. 23, n. 16, p. 7049, 2023.

RIBEIRO, Matheus Henrique Dal Molin *et al.* Variational mode decomposition and bagging extreme learning machine with multi-objective optimization for wind power forecasting. **Applied Intelligence**, v. 54, p. 3119–3134, 2024.

RIBEIRO, Matheus Henrique Dal Molin *et al.* Electricity price forecasting based on self-adaptive decomposition and heterogeneous ensemble learning. **Energies**, v. 13, n. 19, p. 5190, 2020.

RIBEIRO, Matheus Henrique Dal Molin *et al.* Electricity price forecasting based on self-adaptive decomposition and heterogeneous ensemble learning. **Energies**, v. 13, n. 19, p. 5190, 2020.

RIJO, Bruna; NOBRE, Catarina; BRITO, Paulo; FERREIRA, Paulo. An overview of the thermochemical valorization of sewage sludge: Principles and current challenges. **Energies**, MDPI, v. 17, n. 10, p. 2417, 2024.

ŘIMNÁČOVÁ, Daniela *et al.* The effect of carbonization temperature on textural properties of sewage sludge-derived biochars as potential adsorbents. **Journal of Environmental Management**, Elsevier, v. 359, p. 120947, 2024.

RISSMAN, Jeffrey *et al.* Technologies and policies to decarbonize global industry: Review and assessment of mitigation drivers through 2070. **Applied energy**, Elsevier, v. 266, p. 114848, 2020.

RUBEL, Robiul Islam; WEI, Lin. Economic assessment of biochar-based controlled-release nitrogen fertilizer production at different industrial scales. **Waste and Biomass Valorization**, Springer, p. 1–17, 2025. Disponível em: <<https://doi.org/10.1007/s12649-025-03096-4>>.

SAFARIAN, Sahar; SARYAZDI, Seyed Mohammad Ebrahimi; UNNTHORSSON, Runar; RICHTER, Christiaan. Artificial neural network integrated with thermodynamic equilibrium modeling of downdraft biomass gasification-power production plant. **Energy**, Elsevier, v. 213, p. 118800, 2020.

SAFARIAN, Sahar; SARYAZDI, Seyed Mohammad Ebrahimi; UNNTHORSSON, Runar; RICHTER, Christiaan. Dataset of biomass characteristics and net output power from downdraft biomass gasifier integrated power production unit. **Data in brief**, Elsevier, v. 33, p. 106390, 2020.

SAGHAEI, Mahsa; GHADERI, Hadi; SOLEIMANI, Hamed. Design and optimization of biomass electricity supply chain with uncertainty in material quality, availability and market demand. **Energy**, Elsevier, v. 197, p. 117165, 2020.

SAGHEER, Alaa; KOTB, Mostafa. Time series forecasting of petroleum production using deep LSTM recurrent networks. **Neurocomputing**, Elsevier, v. 323, p. 203–213, 2019.

SAHU, Ravi Kumar *et al.* Synthesizing biomass into nano carbon for use in high-performance supercapacitors—a brief critical review. **Journal of Energy Storage**, Elsevier, v. 72, p. 108348, 2023.

SAJDAK, Marcin *et al.* Perspectives of using sewage sludge char in CO₂ sequestration on degraded and brownfield sites. **Energies**, MDPI, v. 16, n. 9, p. 3945, 2023.

SAKARYA, Neslihan; JONG, Robert M de. The spectral analysis of the Hodrick–Prescott filter. **Journal of Time Series Analysis**, Wiley Online Library, v. 43, n. 3, p. 479–489, 2022.

SAMADI, Seyed Hashem; GHOBADIAN, Barat; NOSRATI, Mohsen. Prediction and estimation of biomass energy from agricultural residues using air gasification technology in Iran. **Renewable Energy**, Elsevier, v. 149, p. 1077–1091, 2020.

SANDHAAS, Anna; HARTMANN, Niklas. Pyrolysis as a strategic element in energy system transformation to achieve net zero emissions. **Energy Conversion and Management: X**, Elsevier, v. 26, p. 100970, 2025.

- SANTOS, Diego CBD *et al.* Advancing biochar applications: a review of production processes, analytical methods, decision criteria, and pathways for scalability and certification. **Sustainability**, MDPI, v. 17, n. 6, p. 2685, 2025. Disponível em: <<https://doi.org/10.3390/su17062685>>.
- SANTOS, Guilherme Henrique dos *et al.* Static attitude determination using convolutional neural networks. **Sensors**, v. 21, n. 19, p. 6419, 2021.
- SANTOS, Kenny Vinente dos; COLONETTI, Bruno; FINARDI, Erlon Cristian; ZAVALA, Victor M. Accelerated dual dynamic integer programming applied to short-term power generation scheduling. **International Journal of Electrical Power & Energy Systems**, v. 145, p. 108689, 2023. ISSN 0142-0615.
- SANTOS, T.N. *et al.* Hourly pricing and day-ahead dispatch setting in Brazil: The dessem model. **Electric Power Systems Research**, v. 189, p. 106709, 2020. ISSN 0378-7796.
- SCHENUIT, Felix *et al.* Taking stock of carbon dioxide removal policy in emerging economies: developments in brazil, china, and india. **Climate Policy**, Taylor & Francis, v. 25, n. 1, p. 89–108, 2025. Disponível em: <<https://doi.org/10.1080/14693062.2024.2353148>>.
- SEKHAR, S Joseph *et al.* Production and utilization of green ammonia for decarbonizing the energy sector with a discrete focus on sustainable development goals and environmental impact and technical hurdles. **Fuel**, Elsevier, v. 360, p. 130626, 2024.
- SEMAN, Laio Oriel *et al.* Simultaneously anomaly detection and forecasting for predictive maintenance using a zero-cost differentiable architecture search-based network. **Computers & Industrial Engineering**, v. 208, p. 111412, 2025.
- SEMAN, Laio Oriel; STEFENON, Stefano Frizzo; MARIANI, Viviana Cocco; COELHO, Leandro Santos. Ensemble learning methods using the Hodrick–Prescott filter for fault forecasting in insulators of the electrical power grids. **International Journal of Electrical Power & Energy Systems**, v. 152, p. 109269, 2023. ISSN 0142-0615.
- SEME, Sebastijan; ŠTUMBERGER, Bojan; HADŽISELIMOVIĆ, Miralem; SREDENŠEK, Klemen. Solar photovoltaic tracking systems for electricity generation: A review. **Energies**, MDPI, v. 13, n. 16, p. 4224, 2020.
- SEMERTZIS, Ioannis *et al.* Power system stability analysis from cyber attacks perspective. **IEEE Access**, IEEE, 2024.
- SENGAN, Sudhakar *et al.* Detection of false data cyber-attacks for the assessment of security in smart grid using deep learning. **Computers & Electrical Engineering**, Elsevier, v. 93, p. 107211, 2021.
- SHAHABUDDIN, M.; KIBRIA, M.; BHATTACHARYA, S. Evaluation of high-temperature pyrolysis and co₂ gasification performance of bituminous coal in an entrained flow gasifier. **Journal of the Energy Institute**, v. 94, p. 294–309, 2021.
- SHAHBEIG, Hossein; NOSRATI, Mohsen. Pyrolysis of municipal sewage sludge for bioenergy production: Thermo-kinetic studies, evolved gas analysis, and techno-socio-economic assessment. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 119, p. 109567, 2020.

SHAO, Shuai *et al.* Analysis of machine learning models for wastewater treatment plant sludge output prediction. **Sustainability**, MDPI, v. 15, n. 18, p. 13380, 2023.

SHARMA, Abhishek; PAREEK, Vishnu; ZHANG, Dongke. Biomass pyrolysis—a review of modelling, process parameters and catalytic studies. **Renewable and sustainable energy reviews**, Elsevier, v. 50, p. 1081–1096, 2015.

SHARMA, Amit Kumar; GHODKE, Praveen Kumar; CHEN, Wei-Hsin. Progress in green adsorbent technologies from sewage sludge for wastewater remediation and carbon capture: A sustainable approach towards clean environment. **Current Opinion in Green and Sustainable Chemistry**, Elsevier, v. 46, p. 100883, 2024.

SHARMA, Shivom; CELEBI, Ayse Dilan; MARÉCHAL, François. Robust multi-objective optimization of gasifier and solid oxide fuel cell plant for electricity production using wood. **Energy**, Elsevier, v. 137, p. 811–822, 2017.

SHAW, Rohit; MUKHERJEE, Soumyajit. The development of carbon capture and storage (ccs) in india: A critical review. **Carbon Capture Science & Technology**, Elsevier, v. 2, p. 100036, 2022.

SHEN, Jia *et al.* Effect of co-pyrolysis of sewage sludge with different plastics on the nitrogen, sulfur, and chlorine releasing characteristics and the heavy metals ecological risk of biochar. **Journal of Environmental Chemical Engineering**, Elsevier, p. 110406, 2023.

SHI, Hanxiao *et al.* A CNN-LSTM based deep learning model with high accuracy and robustness for carbon price forecasting: A case of Shenzhen's carbon market in China. **Journal of Environmental Management**, Elsevier, v. 352, p. 120131, 2024.

SHI, Jian; TEH, Jiashen. Load forecasting for regional integrated energy system based on complementary ensemble empirical mode decomposition and multi-model fusion. **Applied Energy**, Elsevier, v. 353, p. 122146, 2024.

SHI, Long *et al.* Robust kernel adaptive filtering for nonlinear time series prediction. **Signal Processing**, Elsevier, v. 210, p. 109090, 2023.

SHI, Tao; MOKTADIR, Md Abdul; REN, Jingzheng; SHEN, Weifeng. Comparative economic, environmental and exergy analysis of power generation technologies from the waste sludge treatment. **Energy Conversion and Management**, Elsevier, v. 286, p. 117074, 2023.

SILVA, Evandro Cardozo da; FINARDI, Erlon Cristian; STEFENON, Stefano Frizzo. Enhancing hydroelectric inflow prediction in the Brazilian power system: A comparative analysis of machine learning models and hyperparameter optimization for decision support. **Electric Power Systems Research**, v. 230, p. 110275, 2024.

SILVEIRA, Andrei Rei Rodrigues; NADALETI, Willian César; PRZYBYLA, Grzegorz; FILHO, Paulo Belli. Potential use of methane and syngas from residues generated in rice industries of pelotas, rio grande do sul: Thermal and electrical energy. **Renewable energy**, Elsevier, v. 134, p. 1003–1016, 2019.

SINGH, Gurmail; STEFENON, Stefano Frizzo; YOW, Kin-Choong. Interpretable visual transmission lines inspections using pseudo-prototypical part network. **Machine Vision and Applications**, Springer, v. 34, n. 3, p. 41, 2023.

SINGH, Harpreet *et al.* A critical review of technologies, costs, and projects for production of carbon-neutral liquid e-fuels from hydrogen and captured co 2. **Energy Advances**, Royal Society of Chemistry, v. 1, n. 9, p. 580–605, 2022.

SLEZAK, Radoslaw; UNYAY, Hilal; SZUFA, Szymon; LEDAKOWICZ, Stanislaw. An extensive review and comparison of modern biomass reactors torrefaction vs. biomass pyrolyzers—part 2. **Energies**, MDPI, v. 16, n. 5, p. 2212, 2023.

SMITH, Jane; KUMAR, Raj. Composting as a sustainable method for sludge management. **Waste Management**, v. 122, p. 145–153, 2021.

SMYL, Slawek; DUDEK, Grzegorz; PEŁKA, Paweł. Es-drnn: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. **IEEE Transactions on Neural Networks and Learning Systems**, IEEE, v. 35, n. 8, p. 11346–11358, 2023.

SOBOLEWSKI, Łukasz; MICZULSKI, Wiesław. Methods of constructing time series for predicting local time scales by means of a GMDH-type neural network. **Applied Sciences**, MDPI, v. 11, n. 12, p. 5615, 2021.

SONG, Jiancai *et al.* Predicting hourly heating load in a district heating system based on a hybrid CNN-LSTM model. **Energy and Buildings**, Elsevier, v. 243, p. 110998, 2021.

SOUZA, Bruno José; STEFENON, Stefano Frizzo; SINGH, Gurmail; FREIRE, Roberto Zanetti. Hybrid-YOLO for classification of insulators defects in transmission lines based on UAV. **International Journal of Electrical Power & Energy Systems**, v. 148, p. 108982, 2023.

STAFFINI, Alessio. A cnn–bilstm architecture for macroeconomic time series forecasting. **Engineering Proceedings**, MDPI, v. 39, n. 1, p. 33, 2023.

STANEK, Wojciech; CZARNOWSKA, Lucyna; GAZDA, Wiesław; SIMLA, Tomasz. Thermo-ecological cost of electricity from renewable energy sources. **Renewable Energy**, Elsevier, v. 115, p. 87–96, 2018.

STARKE, Leandro *et al.* Interference recommendation for the pump sizing process in progressive cavity pumps using graph neural networks. **Scientific Reports**, v. 13, n. 1, p. 16884, 2023.

STEFENON, S. F. *et al.* Analysis of the ultrasonic signal in polymeric contaminated insulators through ensemble learning methods. **IEEE Access**, v. 10, p. 33980–33991, 2022.

STEFENON, Stefano Frizzo; CRISTOFORETTI, Marco; CIMATTI, Alessandro. Automatic digitalization of railway interlocking systems engineering drawings based on hybrid machine learning methods. **Expert Systems with Applications**, v. 281, p. 127532, 2025. ISSN 0957-4174.

STEFENON, Stefano Frizzo; CRISTOFORETTI, Marco; CIMATTI, Alessandro. Automatic digitalization of railway interlocking systems engineering drawings based on hybrid machine learning methods. **Expert Systems with Applications**, Elsevier, v. 281, p. 127532, 2025.

STEFENON, Stefano Frizzo *et al.* Photovoltaic power forecasting using wavelet neuro-fuzzy for active solar trackers. **Journal of Intelligent & Fuzzy Systems**, IOS Press, v. 40, n. 1, p. 1083–1096, 2021.

STEFENON, Stéfano Frizzo *et al.* Hybrid deep learning for power generation forecasting in active solar trackers. **IET Generation, Transmission & Distribution**, v. 14, n. 23, p. 5667–5674, 2020.

STEFENON, Stéfano Frizzo *et al.* Wavelet group method of data handling for fault prediction in electrical power insulators. **International Journal of Electrical Power & Energy Systems**, v. 123, p. 106269, 2020.

STEFENON, Stefano Frizzo *et al.* Hybrid wavelet stacking ensemble model for insulators contamination forecasting. **IEEE Access**, v. 9, p. 66387–66397, 2021.

STEFENON, Stefano Frizzo *et al.* Time series forecasting using ensemble learning methods for emergency prevention in hydroelectric power plants with dam. **Electric Power Systems Research**, v. 202, p. 107584, 2022.

STEFENON, Stefano Frizzo; SEMAN, Laio Oriel; AQUINO, Luiza Scapinello; COELHO, Leandro dos Santos. Wavelet-Seq2Seq-LSTM with attention for time series forecasting of level of dams in hydroelectric power plants. **Energy**, Elsevier, v. 274, p. 127350, 2023.

STEFENON, Stefano Frizzo *et al.* Hypertuned temporal fusion transformer for multi-horizon time series forecasting of dam level in hydroelectric power plants. **International Journal of Electrical Power & Energy Systems**, v. 157, p. 109876, 2024.

STEFENON, Stefano Frizzo *et al.* Hypertuned-YOLO for interpretable distribution power grid fault location based on EigenCAM. **Ain Shams Engineering Journal**, p. 102722, 2024.

STEFENON, Stefano Frizzo; SEMAN, Laio Oriel; MARIANI, Viviana Cocco; COELHO, Leandro Santos. Aggregating prophet and seasonal trend decomposition for time series forecasting of Italian electricity spot prices. **Energies**, v. 16, n. 3, p. 1371, 2023.

STEFENON, Stefano Frizzo *et al.* Group method of data handling using Christiano-Fitzgerald random walk filter for insulator fault prediction. **Sensors**, v. 23, n. 13, p. 6118, 2023.

STEFENON, S. F. *et al.* Optimal design of electrical power distribution grid spacers using finite element method. **IET Generation, Transmission & Distribution**, v. 16, n. 9, p. 1865–1876, 2022.

STEFENON, Stefano Frizzo *et al.* Hypertuned wavelet convolutional neural network with long short-term memory for time series forecasting in hydroelectric power plants. **Energy**, v. 313, p. 133918, 2024.

STEFENON, Stefano Frizzo *et al.* Neural hierarchical interpolation time series (NHITS) for reservoir level multi-horizon forecasting in hydroelectric power plants. **IEEE Access**, v. 13, p. 54853–54865, 2025.

STEFENON, Stefano Frizzo *et al.* Optimized hybrid YOLOu-Quasi-ProtoPNet for insulators classification. **IET Generation, Transmission & Distribution**, v. 17, n. 15, p. 3501–3511, 2023.

STEFENON, S. F.; SINGH, G.; YOW, K.-C.; CIMATTI, A. Semi-ProtoPNet deep neural network for the classification of defective power grid distribution structures. **Sensors**, v. 22, n. 13, p. 4859, 2022.

STEK, Pieter E; OLIVEIRA, Renato Lima-de; VASUDHEVAN, Thessa. The development of carbon markets in upper-middle-income countries. **Regulation & Governance**, Wiley Online Library, v. 19, n. 2, p. 482–495, 2025. Disponível em: <<https://doi.org/10.1111/rego.70010>>.

SU, Guangcan *et al.* Carbon-negative co-production of methanol and activated carbon from bagasse pyrolysis, physical activation, chemical looping, and methanol synthesis. **Energy Conversion and Management**, Elsevier, v. 293, p. 117481, 2023.

SUBRAMANIAN, Navaneethan; MADEJSKI, Paweł. Analysis of co2 capture process from flue-gases in combined cycle gas turbine power plant using post-combustion capture technology. **Energy**, Elsevier, v. 282, p. 128311, 2023.

SUDALAIMUTHU, Pitchaiah; SATHYAMURTHY, Ravishankar. Forecast sustainable and renewable hydrogen production via circular bio-economy of agro waste. **International Journal of Hydrogen Energy**, Elsevier, 2024.

SUGURBEKOVA, Gulnar *et al.* Sewage sludge management and application in the form of sustainable fertilizer. **Sustainability**, MDPI, v. 15, n. 7, p. 6112, 2023. Disponível em: <<https://doi.org/10.3390/su15076112>>.

SUN, Hao *et al.* Carbon balance analysis of sewage sludge biochar-to-soil system. **Journal of Cleaner Production**, Elsevier, v. 358, p. 132057, 2022. Disponível em: <<https://doi.org/10.1016/j.jclepro.2022.132057>>.

SUN, Lianpeng *et al.* Machine learning for municipal sludge recycling by thermochemical conversion towards sustainability. **Bioresource technology**, Elsevier, v. 394, p. 130254, 2024.

SUN, Yingying *et al.* Technology selection for capturing co2 from wood pyrolysis. **Energy Conversion and Management**, Elsevier, v. 266, p. 115835, 2022.

SYGUŁA, Ewa; ŁYCZKO, Jacek; BIAŁOWIEC, Andrzej. Dataset on fuel properties and volatile organic compounds from chemically synthesized biomass components for modeling and predicting biomass properties in pyrolysis processes. **Data in Brief**, Elsevier, v. 59, p. 111296, 2025.

TALBI, El Hachmi; ABAALI, Lhoussine; SKOURI, Rachid; MOUDDEN, Mustapha El. Solution of economic and environmental power dispatch problem of an electrical power system using bfgs-al algorithm. **Procedia Computer Science**, Elsevier, v. 170, p. 857–862, 2020.

TANG, Yuzhou; LI, Yue; COCKERILL, Tim T. Environmental and economic spatial analysis system for biochar production–case studies in the east of england and the east midlands. **Biomass and Bioenergy**, Elsevier, v. 184, p. 107187, 2024. Disponível em: <<https://doi.org/10.1016/j.biombioe.2024.107187>>.

TANVEER, Umair; ISHAQ, Shamaila; HOANG, Thinh Gia. Enhancing carbon trading mechanisms through innovative collaboration: Case studies from developing nations. **Journal of Cleaner Production**, Elsevier, v. 482, p. 144122, 2024. Disponível em: <<https://doi.org/10.1016/j.jclepro.2024.144122>>.

TARPANI, Raphael Ricardo Zepon; AZAPAGIC, Adisa. Life cycle sustainability assessment of advanced treatment techniques for urban wastewater reuse and sewage sludge resource recovery. **Science of The Total Environment**, Elsevier, v. 869, p. 161771, 2023.

TATIPATRI, Naveen; ARUN, SL. A comprehensive review on cyber-attacks in power systems: Impact analysis, detection, and cyber security. **IEEE Access**, IEEE, v. 12, p. 18147–18167, 2024.

TESFAMICHAEL, Brook; MONTASTRUC, Ludovic; NEGNY, Stéphane; YIMAM, Abubeker. Designing and planning of ethiopia's biomass-to-biofuel supply chain through integrated strategic-tactical optimization model considering economic dimension. **Computers & Chemical Engineering**, Elsevier, v. 153, p. 107425, 2021.

THANH, Phuong Nguyen; CHO, Ming-Yuan. Advanced aiot for failure classification of industrial diesel generators based hybrid deep learning cnn-bilstm algorithm. **Advanced Engineering Informatics**, Elsevier, v. 62, p. 102644, 2024.

THIRUGNANAM, Kannan *et al.* Energy management for renewable microgrid in reducing diesel generators usage with multiple types of battery. **IEEE Transactions on Industrial Electronics**, IEEE, v. 65, n. 8, p. 6772–6786, 2018.

TOMCZYK, Agnieszka; SOKOŁOWSKA, Zofia; BOGUTA, Patrycja. Biochar physicochemical properties: pyrolysis temperature and feedstock kind effects. **Reviews in Environmental Science and Bio/Technology**, Springer, v. 19, n. 1, p. 191–215, 2020.

TORRES, José F; MARTÍNEZ-ÁLVAREZ, Francisco; TRONCOSO, Alicia. A deep LSTM network for the spanish electricity consumption forecasting. **Neural Computing and Applications**, Springer, v. 34, n. 13, p. 10533–10545, 2022.

TRABELSI, Aïda Ben Hassen *et al.* Municipal sewage sludge energetic conversion as a tool for environmental sustainability: production of innovative biofuels and biochar. **Environmental Science and Pollution Research**, Springer, v. 28, p. 9777–9791, 2021.

TROLLIP, Brendon; MERCKEL, Ryan David. Production of a nutrient enriched biochar: a techno-economic feasibility analysis. **Biofuels, Bioproducts and Biorefining**, Wiley Online Library, 2025. Disponível em: <<https://doi.org/10.1002/bbb.2812>>.

TULESKI, Bernardo Luis *et al.* Audio-based engine fault diagnosis with wavelet, markov blanket, rocket, and optimized machine learning classifiers. **Sensors (Basel, Switzerland)**, v. 24, n. 22, p. 7316, 2024.

VALI, Naeimeh *et al.* Slow-pyrolysis of municipal sewage sludge: biochar characteristics and advanced thermodynamics. **Biomass Conversion and Biorefinery**, Springer, p. 1–21, 2025.

VARINY, M. *et al.* Advances in biomass co-combustion with fossil fuels in the european context: A review. **Processes**, v. 9, n. 1, p. 100, 2021.

VELIDANDI, Aditya *et al.* State-of-the-art and future directions of machine learning for biomass characterization and for sustainable biorefinery. **Journal of Energy Chemistry**, Elsevier, 2023.

VICTORIA, A Helen; MARAGATHAM, Ganesh. Automatic tuning of hyperparameters using bayesian optimization. **Evolving Systems**, Springer, v. 12, n. 1, p. 217–223, 2021.

WANG, Chang'an *et al.* The impact of fintech on corporate carbon emissions: Towards green and sustainable development. **Business Strategy and the Environment**, Wiley Online Library, v. 33, n. 6, p. 5776–5796, 2024. Disponível em: <<https://doi.org/10.1002/bse.3778>>.

WANG, Kehua; NAKAKUBO, Toyohiko. Design of a sewage sludge energy conversion technology introduction scenario for large city sewage treatment plants in japan: Focusing on zero fuel consumption. **Journal of Cleaner Production**, Elsevier, v. 379, p. 134794, 2022.

WANG, Liuwei *et al.* Role of biochar toward carbon neutrality. **Carbon Research**, Springer, v. 2, n. 1, p. 2, 2023.

WANG, Ming-xi *et al.* Green fabrication of hierarchically porous carbon microtubes from biomass waste via self-activation for high-energy-density supercapacitor. **Journal of Power Sources**, Elsevier, v. 560, p. 232703, 2023.

WANG, Qi; BU, Siqi; HE, Zhengyou; DONG, Zhao Yang. Toward the prediction level of situation awareness for electric power systems using CNN-LSTM network. **IEEE Transactions on Industrial Informatics**, IEEE, v. 17, n. 10, p. 6951–6961, 2020.

WANG, Wu *et al.* Cyber-attacks detection in industrial systems using artificial intelligence-driven methods. **International journal of critical infrastructure protection**, Elsevier, v. 38, p. 100542, 2022.

WANG, Xilu; JIN, Yaochu; SCHMITT, Sebastian; OLHOFER, Markus. Recent advances in bayesian optimization. **ACM Computing Surveys**, ACM New York, NY, v. 55, n. 13s, p. 1–36, 2023.

WANG, Yifei; LEE, Sanghyun. Lifecycle ghg emissions from landfilling sludge: A case study. **Resources, Conservation and Recycling**, v. 149, p. 667–674, 2019.

WANG, Yajun; ZHU, Jianping; KANG, Renke. Destformer: A transformer based on explicit seasonal–trend decomposition for long-term series forecasting. **Applied Sciences**, MDPI, v. 13, n. 18, p. 10505, 2023.

WANG, Zhenghong *et al.* A lightweight multi-layer perceptron for efficient multivariate time series forecasting. **Knowledge-Based Systems**, Elsevier, v. 288, p. 111463, 2024.

WEI, Ping; ZHOU, Jingzi; REN, Xiaohang; HUYNH, Luu Duc Toan. Financialisation of the european union emissions trading system and its influencing factors in quantiles. **International Journal of Finance & Economics**, Wiley Online Library, v. 30, n. 1, p. 925–940, 2025. Disponível em: <<https://doi.org/10.1002/ijfe.2950>>.

WIENCHOL, Paulina; SZŁEK, Andrzej; DITARANTO, Mario. Waste-to-energy technology integrated with carbon capture—challenges and opportunities. **Energy**, Elsevier, v. 198, p. 117352, 2020.

WILK, Małgorzata; ŚLIZ, Maciej; CZERWIŃSKA, Klaudia; ŚLEDŹ, Małgorzata. The effect of an acid catalyst on the hydrothermal carbonization of sewage sludge. **Journal of Environmental Management**, Elsevier, v. 345, p. 118820, 2023.

WOLLNIK, Ronja *et al.* Scenario storylines for carbon dioxide removal in germany: Drawing from regional perspectives. **GCB Bioenergy**, Wiley Online Library, v. 17, n. 9, p. e70075, 2025. Disponível em: <<https://doi.org/10.1111/gcbb.70075>>.

WU, Wenjun *et al.* Adsorption of co₂ by sludge/bamboo shoot shell hybrid biochar prepared by a single-step k₂co₃ activation. **Fuel**, Elsevier, v. 381, p. 133555, 2025.

WU, Xinyu; DOU, Chunxia; YUE, Dong. Electricity load forecast considering search engine indices. **Electric Power Systems Research**, Elsevier, v. 199, p. 107398, 2021.

XIANG, Yue *et al.* Low-carbon economic dispatch of electricity-gas systems. **Energy**, Elsevier, v. 226, p. 120267, 2021.

XIE, Hailun; ZHANG, Li; LIM, Chee Peng. Evolving CNN-LSTM models for time series prediction using enhanced grey wolf optimizer. **IEEE access**, IEEE, v. 8, p. 161519–161541, 2020.

XIE, Shize *et al.* Coal power decarbonization via biomass co-firing with carbon capture and storage: Tradeoff between exergy loss and ghg reduction. **Energy Conversion and Management**, Elsevier, v. 288, p. 117155, 2023.

XIONG, Jinlin *et al.* A dual-scale deep learning model based on elm-bilstm and improved reptile search algorithm for wind power prediction. **Energy**, Elsevier, v. 266, p. 126419, 2023.

XU, Li *et al.* Offshore wind speed assessment with statistical and attention-based neural network methods based on STL decomposition. **Renewable Energy**, Elsevier, v. 216, p. 119097, 2023.

XU, Mingkuo; REN, Hui; CHEN, Ping; XIN, Guoyu. On the V2G capacity of shared electric vehicles and its forecasting through MAML-CNN-LSTM-Attention algorithm. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 18, n. 6, p. 1158–1171, 2024.

XU, Tao; ZHENG, Xiuren; XU, Jue; WU, Yongping. Hydrogen-rich gas production from two-stage catalytic pyrolysis of pine sawdust with nano-nio/al₂o₃ catalyst. **Catalysts**, MDPI, v. 12, n. 3, p. 256, 2022.

YAASHIKAA, PR *et al.* A biotechnological roadmap for decarbonization systems combined into bioenergy production: Prelude of environmental life-cycle assessment. **Chemosphere**, Elsevier, p. 138670, 2023.

YADAV, Anita; JHA, CK; SHARAN, Aditi. Optimizing LSTM for time series prediction in Indian stock market. **Procedia Computer Science**, Elsevier, v. 167, p. 2091–2100, 2020.

YAHYA, Nur Syahira Mohd; NG, Lik Yin; ANDIAPPAN, Viknesh. Optimisation and planning of biomass supply chain for new and existing power plants based on carbon reduction targets. **Energy**, Elsevier, v. 237, p. 121488, 2021.

YAMAGUCHI, Cristina Keiko; STEFENON, Stefano Frizzo; SANTANA, Juan Francisco De Paz; LEITHARDT, Valderi Reis Quietinho. Are graph neural networks better than standard classifiers? In: **International Conference on Disruptive Technologies, Tech Ethics and Artificial Intelligence**. Salamanca, Spain: Springer, 2025. p. 36–47.

YAMASAKI, Marcos *et al.* Optimized hybrid ensemble learning approaches applied to very short-term load forecasting. **International Journal of Electrical Power & Energy Systems**, v. 155, p. 109579, 2024.

YAMASAKI, Marcos *et al.* Optimized hybrid ensemble learning approaches applied to very short-term load forecasting. **International Journal of Electrical Power & Energy Systems**, v. 155, p. 109579, 2024.

- YANG, Baijie *et al.* Resilience assessment methodologies and enhancement strategies of multi-energy cyber-physical systems of the distribution network. **IET Energy Systems Integration**, Wiley Online Library, v. 4, n. 2, p. 171–191, 2022.
- YANG, Caiyun *et al.* Valorization of biomass-derived polymers to functional biochar materials for supercapacitor applications via pyrolysis: Advances and perspectives. **Polymers**, MDPI, v. 15, n. 12, p. 2741, 2023.
- YANG, Jianqiao *et al.* Novel design concept for a commercial-scale plant for supercritical water oxidation of industrial and sewage sludge. **Journal of environmental management**, Elsevier, v. 233, p. 131–140, 2019.
- YANG, Mengjie *et al.* Greenhouse gas emissions from wastewater treatment plants in china: Historical emissions and future mitigation potentials. **Resources, Conservation and Recycling**, Elsevier, v. 190, p. 106794, 2023.
- YANG, Shi-guan *et al.* Site selection decision framework for biomass pyrolysis project based on a mixed method under probabilistic linguistic environment and low carbon perspective: A case study in china. **Energy**, Elsevier, v. 272, p. 127118, 2023.
- YANG, Ting; LIU, Yuzhe; LI, Wei. Attack and defence methods in cyber-physical power system. **IET Energy Systems Integration**, Wiley Online Library, v. 4, n. 2, p. 159–170, 2022.
- YANG, Xiaoxia *et al.* Sorption-enhanced thermochemical conversion of sewage sludge to syngas with intensified carbon utilization. **Applied Energy**, Elsevier, v. 254, p. 113663, 2019.
- YIN, Caichun *et al.* Ecosystem carbon sequestration service supports the sustainable development goals progress. **Journal of Environmental Management**, Elsevier, v. 330, p. 117155, 2023.
- YOON, Ha-Jun *et al.* Sustainable and feasible carbon capture and utilization pathways towards net-zero. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 211, p. 115331, 2025. Disponível em: <<https://doi.org/10.1016/j.rser.2025.115331>>.
- YU, Haoyang *et al.* Data-driven optimization of pollutant emission and operational efficiency for circulating fluidized bed unit. **Energy**, Elsevier, v. 281, p. 128338, 2023.
- YUAN, Chuan *et al.* Recent advances and challenges in biomass-derived carbon materials for supercapacitors: A review. **Fuel**, Elsevier, v. 362, p. 130795, 2024.
- YUE, Dajun; YOU, Fengqi; SNYDER, Seth W. Biomass-to-bioenergy and biofuel supply chain optimization: Overview, key issues and challenges. **Computers & Chemical Engineering**, Elsevier, v. 66, p. 36–56, 2014.
- YUSUF, Syed Adnan *et al.* Predicting catastrophic temperature changes based on past events via a CNN-LSTM regression mechanism. **Neural Computing and Applications**, Springer, v. 33, n. 15, p. 9775–9790, 2021.
- ZAKER, Ali *et al.* Carbon-based materials for co2 capture: their production, modification and performance. **Journal of Environmental Chemical Engineering**, Elsevier, p. 109741, 2023.

ZHANG, Bin; WU, Xuewei; GHIAS, Amer MYM; CHEN, Zhe. Coordinated carbon capture systems and power-to-gas dynamic economic energy dispatch strategy for electricity–gas coupled systems considering system uncertainty: An improved soft actor–critic approach. **Energy**, Elsevier, v. 271, p. 126965, 2023.

ZHANG, Dongdong *et al.* A comprehensive overview of modeling approaches and optimal control strategies for cyber-physical resilience in power systems. **Renewable Energy**, Elsevier, v. 189, p. 1383–1406, 2022.

ZHANG, Guangming *et al.* Modeling and optimal dispatch of a carbon-cycle integrated energy system for low-carbon and economic operation. **Energy**, Elsevier, v. 240, p. 122795, 2022.

ZHANG, Hui; CHEN, Long. Co2 emissions from incineration of sewage sludge in china. **Environmental Science and Technology**, v. 56, n. 12, p. 7030–7037, 2022.

ZHANG, Jifu *et al.* Thermodynamic analysis of soft–cchp system based on municipal sludge plasma gasification with carbon capture. **Applied Energy**, Elsevier, v. 336, p. 120822, 2023.

ZHANG, Jian *et al.* Patchttn: Patch-based transformer convolutional network for times series analysis. In: **Proceedings of the 2024 3rd International Symposium on Computing and Artificial Intelligence**. [S.l.: s.n.], 2024. p. 1–9.

ZHANG, Qianyun; BARRI, Kaveh; BABANAJAD, Saeed K; ALAVI, Amir H. Real-time detection of cracks on concrete bridge decks using deep learning in the frequency domain. **Engineering**, Elsevier, v. 7, n. 12, p. 1786–1796, 2021.

ZHANG, Qionghua *et al.* A novel carbon emission evaluation model for anaerobic-anoxic-oxic urban sewage treatment. **Journal of Environmental Management**, Elsevier, v. 350, p. 119640, 2024.

ZHANG, Ran *et al.* Deciphering the electricity–carbon market nexus: Challenges and prospects of electricity–carbon coupling. **Energy Internet**, Wiley Online Library, v. 1, n. 1, p. 34–51, 2024. Disponível em: <<https://doi.org/10.1049/ein2.12003>>.

ZHANG, Xiaoyong *et al.* Comparative study of different sewage sludge incineration treatments based on environmental and economic life cycle assessment. **Waste Management & Research**, SAGE Publications Sage UK: London, England, v. 42, n. 5, p. 418–429, 2024.

ZHANG, Xiaojing; GAO, Qi; QU, Yunqing. A k-nearest neighbors approach for mitigating false data injection attacks in industrial microgrids. **Smart Grids and Sustainable Energy**, Springer, v. 10, n. 2, p. 1–12, 2025.

ZHANG, Yong *et al.* Biomass-derived carbon for supercapacitors electrodes—a review of recent advances. **Inorganic Chemistry Communications**, Elsevier, v. 153, p. 110768, 2023.

ZHANG, Yuying *et al.* Scaling biochar solutions for urban carbon dioxide removal. **One Earth**, Elsevier, v. 7, n. 9, p. 1481–1486, 2024. Disponível em: <[10.1016/j.oneear.2024.08.008](https://doi.org/10.1016/j.oneear.2024.08.008)>.

ZHANG, Z. *et al.* Hydrothermal carbonization of biomass and waste: A review. **Environmental Chemistry Letters**, v. 20, p. 211–221, 2022.

ZHAO, He *et al.* Week-ahead hourly solar irradiation forecasting method based on iceemdan and timesnet networks. **Renewable Energy**, Elsevier, v. 220, p. 119706, 2024.

ZHAO, Lei *et al.* Sewage sludge derived biochar for environmental improvement: Advances, challenges, and solutions. **Water Research X**, Elsevier, p. 100167, 2023.

ZHAO, Tianxiang *et al.* Improving resilience of cyber–physical power systems against cyber attacks through strategic energy storage deployment. **Reliability Engineering & System Safety**, Elsevier, v. 252, p. 110438, 2024.

ZHENG, Wendi *et al.* Optimal dispatch of nearly-zero carbon integrated energy system considering waste incineration plant-carbon capture system and market mechanisms. **International Journal of Hydrogen Energy**, Elsevier, 2023.

ZHENG, Xinyu; LAM, Ka Leung. An overview of environmental co-benefits and trade-offs to reduce greenhouse gas emissions in municipal wastewater management. **Sustainable Production and Consumption**, Elsevier, 2024.

ZHONG, Jiayong; XIONG, Xiaofu. Data security storage method for power distribution internet of things in cyber-physical energy systems. **Wireless Communications and Mobile Computing**, Wiley Online Library, v. 2021, n. 1, p. 6694729, 2021.

ZHOU, Ao *et al.* Process design and optimization on self-sustaining pyrolysis and carbonization of municipal sewage sludge. **Waste Management**, Elsevier, v. 159, p. 125–133, 2023.

ZHOU, Haoyi *et al.* Informer: Beyond efficient transformer for long sequence time-series forecasting. In: **Proceedings of the AAAI conference on artificial intelligence**. [S.l.: s.n.], 2021. v. 35, p. 11106–11115.

ZHOU, Kai *et al.* Waste to worth: A new approach to treat wastewater sludge. **Separation and Purification Technology**, Elsevier, v. 305, p. 122412, 2023.

ZHOU, K. *et al.* Waste to worth: A new approach to treat wastewater sludge. **Separation and Purification Technology**, v. 305, p. 122412, 2023.

ZHU, Guoxiong *et al.* Applying deep learning and automated machine learning for enhanced state monitoring and health assessment of high-pressure heater in thermal power units. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 141, p. 109805, 2025.

ZHU, Xinzhe *et al.* Machine learning-assisted exploration for carbon neutrality potential of municipal sludge recycling via hydrothermal carbonization. **Bioresource Technology**, Elsevier, v. 369, p. 128454, 2023.

ZHU, Yuhan *et al.* Enhanced recovery of phosphorus in sewage sludge-derived biochar with caco₃: Phosphorus speciation and slow-release phosphorus behavior. **Separation and Purification Technology**, Elsevier, v. 311, p. 123325, 2023.

ZUEGE, Cesar Vinicius *et al.* Wind speed forecasting approach using conformal prediction and feature importance selection. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 168, p. 110700, 2025.

ZUIN, Gianluca *et al.* Extreme event counterfactual analysis of electricity consumption in brazil: Historical impacts and future outlook under climate change. **Energy**, Elsevier, p. 128101, 2023.

ZULFIQAR, Muhammad; GAMAGE, Kelum AA; KAMRAN, Muhammad; RASHEED, Muhammad Babar. Hyperparameter optimization of bayesian neural network using bayesian optimization and intelligent feature engineering for load forecasting. **Sensors**, MDPI, v. 22, n. 12, p. 4446, 2022.

APÊNDICES - Artigos publicados

APÊNDICE A – A REVIEW OF AUTOMATION AND SENSORS: PARAMETER CONTROL OF THERMAL TREATMENTS FOR ELECTRICAL POWER GENERATION



sensors



Review

A Review of Automation and Sensors: Parameter Control of Thermal Treatments for Electrical Power Generation

William Gouvêa Buratto ^{1,*} , Rafael Ninno Muniz ^{2,3} , Ademir Nied ¹ , Carlos Frederico de Oliveira Barros ³ , Rodolfo Cardoso ³ and Gabriel Villarrubia Gonzalez ⁴

¹ Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil

² Electrical Engineering Graduate Program, Department of Electrical Engineering, Federal University of Pará (UFPA), Belém 66075-110, Brazil

³ Production Engineering Graduate Program, Department of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras 28895-532, Brazil

⁴ Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, 37008 Salamanca, Spain

* Correspondence: william.buratto@edu.udesc.br

Abstract: This review delves into the critical role of automation and sensor technologies in optimizing parameters for thermal treatments within electrical power generation. The demand for efficient and sustainable power generation has led to a significant reliance on thermal treatments in power plants. However, ensuring precise control over these treatments remains challenging, necessitating the integration of advanced automation and sensor systems. This paper evaluates the pivotal aspects of automation, emphasizing its capacity to streamline operations, enhance safety, and optimize energy efficiency in thermal treatment processes. Additionally, it highlights the indispensable role of sensors in monitoring and regulating crucial parameters, such as temperature, pressure, and flow rates. These sensors enable real-time data acquisition, facilitating immediate adjustments to maintain optimal operating conditions and prevent system failures. It explores the recent technological advancements, including machine learning algorithms and IoT integration, which have revolutionized automation and sensor capabilities in thermal treatment control. Incorporating these innovations has significantly improved the precision and adaptability of control systems, resulting in heightened performance and reduced environmental impact. This review underscores the imperative nature of automation and sensor technologies in thermal treatments for electrical power generation, emphasizing their pivotal role in enhancing operational efficiency, ensuring reliability, and advancing sustainability in power generation processes.

Keywords: automation and sensors; data acquisition; parameter control; thermal treatments; electrical power generation



Citation: Buratto, W.G.; Muniz, R.N.; Nied, A.; Barros, C.F.d.O.; Cardoso, R.; Gonzalez, G.V. A Review of Automation and Sensors: Parameter Control of Thermal Treatments for Electrical Power Generation. *Sensors* **2024**, *24*, 967. <https://doi.org/10.3390/s24030967>

Academic Editor: Roberto Teti

Received: 4 January 2024

Revised: 20 January 2024

Accepted: 25 January 2024

Published: 1 February 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Automation and sensor technologies play a crucial role in optimizing and enhancing various aspects of thermal treatments across different industries. When combined, they allow precise control over temperature, pressure, and other critical parameters during thermal treatments. This contributes to overall energy efficiency and sustainability in thermal treatment operations [1]. These technologies are integral components of the Industry 4.0 paradigm, facilitating the integration of digital equipment for a connected and intelligent manufacturing environment [2]. This includes the use of the Internet of Things (IoT) [3], programmable logic controllers (PLCs) [4], and data analytics to create smart thermal treatment systems.

Considering the need for more efficient thermal systems and a better understanding of electricity generation in this regard, this review is presented. This revision has focused on pyrolysis [5], gasification, and combustion, in addition to the technologies used to control

Received 16 January 2024, accepted 8 February 2024, date of publication 13 February 2024, date of current version 29 February 2024.

Digital Object Identifier 10.1109/ACCESS.2024.3365812



RESEARCH ARTICLE

Seq2Seq-LSTM With Attention for Electricity Load Forecasting in Brazil

WILLIAM GOUVÊA BURATTO¹, RAFAEL NINNO MUNIZ², ADEMIR NIED¹, (Member, IEEE),
AND GABRIEL VILLARRUBIA GONZÁLEZ³

¹Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil

²Production Engineering Graduate Program, Department of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras 28895-532, Brazil

³Expert Systems and Applications Laboratory, Faculty of Science, University of Salamanca, 37008 Salamanca, Spain

Corresponding author: William Gouvêa Buratto (william.buratto@edu.udesc.br)

This work was supported in part by Caracterización, Análisis e Intervención en la Prevención de Riesgos Laborales Enentornos de Trabajo Tradicionales Mediante la Aplicación de Tecnologías Disruptivas—Consejería de Empleo Eindustria under Grant J125; in part by the Coordination for the Improvement of Higher Education Personnel (CAPES), Brazil, under the Doctoral Scholarship under Grant 88887.808258/2023-00; and in part by the Council for Scientific and Technological Development (CNPq) under Grant 310447/2021-6.

ABSTRACT Electricity load forecasting is important to planning the decision-making regarding the use of energy resources, in which the power system must be operated to guarantee the supply of electricity in the future at the lowest possible price. With the rise of the ability of forecasting based on deep learning, these approaches are promising in this context. Considering the attention mechanism promising to capture long-range dependencies, it is highly recommended for sequential data processing, where time series-related tasks stand out. Considering a sequence-to-sequence (Seq2Seq) time series data of the electricity load in Brazil, this paper proposes the use of the long short-term memory (LSTM) with the attention mechanism to perform the time series forecasting. The proposed Seq2Seq-LSTM with attention mechanism outperforms other well-established models. Having a mean absolute error equal to 0.3027 the proposed method is shown to be promising for field applications. The proposed method contributes to time series forecasting by implementing an attention mechanism to Seq2Seq data, therefore, more than one correlated signal can be used to perform the prediction enhancing its capacity when more data is available.

INDEX TERMS Electricity supply industry, energy measurement, forecast uncertainty, time series analysis.

I. INTRODUCTION

In Brazil, the energy dispatch is computed based on a stochastic optimization problem, where the goal is to ensure the availability of energy in the future at a lower cost as possible [1]. Since the power grids are connected in a national interconnected system [2], the generation and transmission are based on the demand of each region, and the management of the use of water (in hydroelectric power plants with dams) is based on this optimization problem [3]. Given this goal, electricity load forecasting is a challenging task.

Load forecasting is an important topic that several researchers have studied since it is relevant for decision-making regarding electrical power management [4], [5], [6], [7]. When renewable energies can not support the electricity

demand, classical power sources are used based on fossil energy, which increases the cost of energy and its price [8]. Given that, energy forecasting can be used for energy planning and improved energy security [9].

Improving the characteristics of energy dispatch and costs with more efficiency from a prediction about the electricity costs, attributed together with the community demands, allows evaluating local load and storage showing behavior patterns about system marginal electricity prices [10]. These advantages can be applied to the contribution of planning new generators or alternative sources acquisitions verifying the correlation between variables and their impacts on the prices [11]. These approaches help to select strategies that consequently promote effective optimization of the grid system and reduction of costs of power plants [12].

Modeling and forecasting of electricity are essential tasks that collaborate to present features and advantages in a

The associate editor coordinating the review of this manuscript and approving it for publication was Reinaldo Tonkoski¹.

APÊNDICE C – WAVELET CNN-LSTM TIME SERIES FORECASTING OF ELECTRICITY POWER GENERATION CONSIDERING BIOMASS THERMAL SYSTEMS

Received: 12 June 2024

Revised: 12 September 2024

Accepted: 24 September 2024

DOI: 10.1049/grd2.13292

IET Generation, Transmission & Distribution



ORIGINAL RESEARCH

Wavelet CNN-LSTM time series forecasting of electricity power generation considering biomass thermal systems

William Gouvêa Buratto¹ | Rafael Ninno Muniz² | Ademir Nied¹ |

Carlos Frederico de Oliveira Barros² | Rodolfo Cardoso² | Gabriel Villarrubia Gonzalez³

¹Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville, Brazil

²Production Engineering Graduate Program, Department Science and Technology, Federal Fluminense University (UFF), Niterói, Brazil

³Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, Salamanca, Spain

Correspondence

William Gouvêa Buratto, Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil.
Email: william.buratto@edu.udesc.br

Funding information

CAPES, Grant/Award Number: 88887.808258/2023-00; CNPq, Grant/Award Number: 310447/2021-6; (PLAUTON) PID2023-151701OB-C21, Grant/Award Number: MCIN/AEI/10.13039/501100011033/FEDER,EU

Abstract

The use of biomass as a renewable energy source for electricity generation has gained attention due to its sustainability and environmental benefits. However, the intermittent electricity demand poses challenges for optimizing electricity generation in thermal systems. Time series forecasting techniques are crucial in addressing these challenges by providing accurate predictions of biomass availability and electricity generation. Here, wavelet transform is applied for denoising, convolutional neural networks (CNN) are used to extract features of the time series, and long short-term memory (LSTM) is applied to perform the predictions. The result of the mean absolute percentage error equal to 0.0148 shows that the wavelet CNN-LSTM is a promising machine-learning methodology for electricity generation forecasting. Additionally, this paper discusses the importance of model evaluation techniques and validation strategies to assess the performance of forecasting models in real-world applications. The major contribution of this paper is related to improving forecasting using a hybrid method that outperforms other models based on deep learning. Finally, future research directions and potential advancements in time series forecasting for biomass thermal systems are outlined to foster continued innovation in sustainable energy generation.

1 | INTRODUCTION

Electricity power generation through biomass thermal systems harnesses the renewable energy stored in organic materials. These systems utilize combustion or gasification processes to convert biomass into energy, which is then used to create steam to drive turbines and generate electricity power [1]. Biomass thermal systems offer a sustainable alternative to fossil fuels. Furthermore, they provide opportunities for waste management and agricultural diversification, turning organic waste into valuable energy resources [2]. The potential to predict the availability of energy in these systems can be valuable information for decision making, which is why time series forecasting is a promising solution that needs to be explored.

Biomass generation represents a sustainable alternative when hydroelectric generation systems do not meet demand and need

to be supplemented by other sources of generation. Considering that solar and wind energy depends on environmental conditions, one alternative is to use biomass as a generation source [3]. However, the cost of generation using thermal energy can be higher than other sources of generation, such as hydroelectric [4]. Based on this challenge, the model proposed here aims to forecast the generation of thermal energy using biomass to aid decision making regarding the management of this resource.

Time series forecasting of electricity generation in thermal systems powered by biomass involves predicting future electricity production based on historical data patterns [5]. These forecasts are crucial for optimizing energy production, managing resources efficiently, and planning for future demand [6]. By analysing past trends in biomass consumption, weather conditions, plant efficiency, and other relevant factors, predictive models can be applied to anticipate future electricity generation levels. This enables stakeholders to decide on energy

This is an open access article under the terms of the Creative Commons Attribution-NonCommercial License, which permits use, distribution and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

© 2024 The Author(s). *IET Generation, Transmission & Distribution* published by John Wiley & Sons Ltd on behalf of The Institution of Engineering and Technology.

APÊNDICE D – TIME SERIES FORECASTING OF THERMAL SYSTEMS DISPATCH IN LEGAL AMAZON USING MACHINE LEARNING



Article

Time Series Forecasting of Thermal Systems Dispatch in Legal Amazon Using Machine Learning

William Gouvêa Buratto ^{1,*}, Rafael Ninno Muniz ^{2,3}, Rodolfo Cardoso ³, Ademir Nied ¹,
Carlos Tavares da Costa, Jr. ² and Gabriel Villarrubia Gonzalez ⁴

- ¹ Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil; ademir.nied@udesc.br
 - ² Electrical Engineering Graduate Program, Department of Electrical Engineering, Federal University of Pará (UFPA), Belém 66075-110, Brazil; muniz@ieec.org
 - ³ Production Engineering Master Program, Institute of Science and Technology, Federal Fluminense University, Rio das Ostras 28895-532, Brazil; rodolfo_cardoso@id.uff.br
 - ⁴ Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, 37008 Salamanca, Spain; gvg@usal.es
- * Correspondence: william.buratto@edu.udesc.br

Abstract: This paper analyzes time series forecasting methods applied to thermal systems in Brazil, specifically focusing on diesel consumption as a key determinant. Recognizing the critical role of thermal systems in ensuring energy stability, especially during low rain seasons, this study employs bagged, boosted, and stacked ensemble learning methods for time series forecasting focusing on exploring consumption patterns and trends. By leveraging historical data, the research aims to predict future diesel consumption within Brazil's thermal energy sector. Based on the bagged ensemble learning approach a mean absolute percentage error of 0.089% and a coefficient of determination of 0.9752 were achieved (average considering 50 experiments), showing it to be a promising model for the short-time forecasting of thermal dispatch for the electric power generation system. The bagged model results were better than for boosted and stacked ensemble learning methods, long short-term memory networks, and adaptive neuro-fuzzy inference systems. Since the thermal dispatch in Brazil is closely related to energy prices, the predictions presented here are an interesting way of planning and decision-making for energy power systems.

Keywords: Time series analysis; diesel consumption; thermal system; forecasting.



Citation: Buratto, W.G.; Muniz, R.N.; Cardoso, R.; Nied, A.; da Costa, C.T., Jr.; Gonzalez, G.V. Time Series Forecasting of Thermal Systems Dispatch in Legal Amazon Using Machine Learning. *Appl. Sci.* **2024**, *14*, 9806. <https://doi.org/10.3390/app14219806>

Academic Editor: Grigorios Beligiannis

Received: 30 August 2024
Revised: 20 October 2024
Accepted: 25 October 2024
Published: 27 October 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Electricity generation and its costs in an isolated system off-grid are mostly related to fuel engines with diesel or natural gas consumption [1], mainly because these energy types are easily transported and they are non-intermittent energy sources in contrast to solar or wind power plants which can be integrated [2]. It is challenging to achieve accurate generation prediction of these cited renewable sources [3], while fossil fuel has significant disadvantages as it generates pollutant emissions and there is a need to refine the oil that is imported in part from foreign countries in the thermal plants of the Brazilian Amazon Region [4].

The interdependence between the nexus of greenhouse emissions, economic growth, financial development, and load demand-supply in the past with the future is important in managing policy recommendations and/or establishing strategies for the corporate sector to adopt business operations with better support technologies to improve profit with ecological efficiency [5]. Determining scenarios that could improve the reduction in carbon dioxide or coordinate carbon capture systems to reach targets considering uncertainties and promoting the best possible adaptability involves following the convergence results of these four parameters [6].

APÊNDICE E – HYBRID GROUP METHOD OF DATA HANDLING FOR TIME-SERIES FORECASTING OF THERMAL GENERATION DISPATCH IN ELECTRICAL POWER SYSTEMS

Electrical Engineering (2025) 107:13929–13944
https://doi.org/10.1007/s00202-025-03242-0

ORIGINAL PAPER



Hybrid group method of data handling for time-series forecasting of thermal generation dispatch in electrical power systems

William Gouvêa Buratto¹ · Rafael Ninno Muniz^{2,3} · Rodolfo Cardoso³ · Ademir Nied¹ · Carlos Tavares da Costa Jr² · Gabriel Villarrubia Gonzalez⁴

Received: 5 May 2025 / Accepted: 11 June 2025 / Published online: 28 June 2025
© The Author(s), under exclusive licence to Springer-Verlag GmbH Germany, part of Springer Nature 2025

Abstract

In the Brazilian power system, challenges are inherent in forecasting thermal generation dispatch, which plays a critical role in ensuring the efficient operation of electrical power systems. Traditional forecasting methods often struggle to capture the dynamic and nonlinear nature of such systems, leading to inaccuracies and inefficiencies. Here, a hybrid group method of data handling (HGMDH) is proposed based on the combination of denoising techniques and a prediction model. By integrating denoising techniques with the prediction model, the proposed approach aims to overcome the limitations of individual methods, enhancing forecasting accuracy and adaptability to different operating conditions. The effectiveness of the HGMDH approach is evaluated through simulations and comparisons with the Christiano–Fitzgerald filter considering a maximum period of oscillations equal to nine. With a mean absolute percentage error of 0.00988, the HGMDH demonstrates superior performance in predicting thermal generation dispatch in electrical power systems. This innovative hybrid approach presents a promising avenue for improving the efficiency and reliability of time-series forecasting in complex energy systems.

Keywords Decision-making · Group method of data handling · Time-series forecasting.

William Gouvêa Buratto
william.buratto@edu.udesc.br

Rafael Ninno Muniz
muniz@ieec.org

Rodolfo Cardoso
rodolfo_cardoso@id.uff.br

Ademir Nied
ademir.nied@udesc.br

Carlos Tavares da Costa Jr
cartav@ufpa.br

Gabriel Villarrubia Gonzalez
gvg@usal.es

- ¹ Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil
- ² Electrical Engineering Graduate Program, Department of Electrical Engineering, Federal University of Pará (UFPA), Belém 66075-110, Brazil
- ³ Production Engineering Graduate Program, Institute of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras 28895-532, Brazil
- ⁴ Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, 37008 Salamanca, Spain

1 Introduction

Electrical dispatch in power systems is determined by consumer demand over time; therefore, there is a need to predict the energy consumption pattern [1]. In Brazil, the power system dispatch is based on a stochastic optimization problem given a short- and long-term horizon, where the power source comes mainly from hydroelectric power plants [2]. In this context, thermal power plants are used when reservoir levels are low, so it is possible to regulate the electricity system to guarantee the supply of energy over time [3].

Given the need for power generation to balance the electrical power system and secure the supply over time, the thermal generation is dispatched [4]. Considering this need, the thermal generation dispatch is a major issue to be evaluated, which is the focus of this paper. This evaluation is even more challenging because of the variation of the rainy season in Brazil [5].

Considering these challenges, the use of artificial intelligence models becomes a promising solution considering their ability to deal with nonlinear patterns [6]. Deep learning structures are getting attention for these applications [7–9]; however, they are not always the best approach since they


APÊNDICE F – HYBRID CF-CNN-BILSTM HYPERTUNED BY BAYESIAN OPTIMIZATION FOR THERMAL POWER GENERATION AND DECARBONIZATION FORECASTING



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

International Journal of Electrical Power and Energy Systems

journal homepage: www.elsevier.com/locate/ijepes



Hybrid CF-CNN-BiLSTM hypertuned by Bayesian optimization for thermal power generation and decarbonization forecasting



William Gouvêa Buratto^{a,b}, Rafael Ninno Muniz^c, Ademir Nied^a, Carlos Frederico de Oliveira Barros^c, Erlon Cristian Finardi^d, Gabriel Villarrubia Gonzalez^b

^a Electrical Engineering Graduate Program, Dep. of Electrical Engineering, Santa Catarina State University (UDESC), Joinville, Brazil

^b Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, Salamanca, Spain

^c Production Engineering Master Program, Institute of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras, Brazil

^d Electrical Engineering Graduate Program, Santa Catarina Federal University (UFSC), Florianópolis, Brazil

ARTICLE INFO

Keywords:

Bayesian optimization
Time series forecasting
Hybrid model
Thermal power generation
Decarbonization

ABSTRACT

Accurate thermal power generation forecasting is essential for grid stability, operational cost reduction, and decarbonization (via CO₂ emission management), but is challenged by noisy, non-linear, temporally dependent data. In this paper, a novel hybrid model integrates a Christiano-Fitzgerald (CF) random walk filter to decompose time series into trend, cyclical, and irregular components for denoising. A convolutional neural network (CNN)-bidirectional long short-term memory (BiLSTM) architecture extracts spatial features and captures temporal dependencies. Bayesian Optimization automates hyperparameter tuning. The model is evaluated on real data from Brazil's Candiota III coal-fired power plant. The proposed hypertuned CF-CNN-BiLSTM significantly outperformed 16 benchmarks. For 6-hour-ahead forecasting, the proposed model achieved root mean squared error (RMSE) of 1.42×10^{-3} , mean absolute percentage error (MAPE) of 0.207%, and mean squared logarithmic error (MSLE) of 1.11×10^{-6} . Statistical analysis over 50 runs confirmed robustness (low mean errors, narrow interquartile ranges), though occasional outliers occurred. The integration of CF filtering, CNN-BiLSTM, and Bayesian optimization delivers high-precision thermal generation forecasts, directly supporting emission reduction strategies. Future work should incorporate exogenous variables like weather and fuel prices.

1. Introduction

Brazil's energy matrix is characterized by a significant reliance on hydroelectric power [1]. This dependence necessitates a sophisticated scheduling framework to manage the temporal and spatial variability of water resources effectively [2]. The Brazilian power system employs a hierarchical scheduling framework that operates across multiple time horizons, each addressing specific objectives and utilizing specialized computational models [3]. The primary objective is to meet projected demand at minimal operating costs while considering the stochastic nature of a hydrothermal base system [4].

Hydropower production is subject to variability due to fluctuating water inflows, which seasonal changes and climatic conditions can influence [5]. Thermal power plants, which are less affected by such variability, play a vital role in compensating for potential shortfalls in hydroelectric generation. Accurate predictions of power generation enable system operators to effectively balance the grid, ensuring a reliable power supply [6].

The cost of generating electricity from thermal sources is generally higher than that from hydroelectric sources, primarily due to fuel expenses and associated environmental costs [7]. By forecasting thermal generation needs, operators can optimize the dispatch of power plants, prioritizing the use of more economical hydroelectric power when available and reserving thermal generation for periods of higher demand or lower hydro availability. This strategy minimizes overall system operating costs [8].

Predicting thermal generation requirements aids in scheduling maintenance activities for both thermal and hydroelectric plants. By anticipating periods when thermal generation will be essential, maintenance can be planned during times of lower demand or higher hydro availability, ensuring that thermal plants are operational when most needed. This foresight enhances the reliability and efficiency of the power system [9].

In energy markets, accurate predictions of generation capacities are vital for trading and contractual agreements. Understanding when

* Corresponding author.

E-mail address: william.buratto@edu.udesc.br (W.G. Buratto).

<https://doi.org/10.1016/j.ijepes.2025.111199>

Received 3 July 2025; Received in revised form 10 September 2025; Accepted 24 September 2025

Available online 9 October 2025

0142-0615/© 2025 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY-NC license (<http://creativecommons.org/licenses/by-nc/4.0/>).



Review

State-of-the-Art Decarbonization in Sludge Thermal Treatments for Electrical Power Generation Considering Sensors and the Application of Artificial Intelligence

Rafael Ninno Muniz ¹, William Gouvêa Buratto ², Rodolfo Cardoso ¹, Carlos Frederico de Oliveira Barros ¹, Ademir Nied ^{2,*} and Gabriel Villarrubia Gonzalez ³

¹ Production Engineering Graduate Program, Department of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras 28895-532, Brazil; muniz@ieeee.org (R.N.M.); rodolfo_cardoso@id.uff.br (R.C.); carlosfredericobarros@id.uff.br (C.F.d.O.B.)

² Electrical Engineering Graduate Program, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville 89219-710, Brazil; william.buratto@edu.udesc.br

³ Expert Systems and Applications Lab, Faculty of Science, University of Salamanca, 37008 Salamanca, Spain; gvg@usal.es

* Correspondence: ademir.nied@udesc.br

Abstract

This study explores innovative strategies for decarbonizing sludge thermal treatments used in electrical power generation, with a focus on integrating sensor technologies and artificial intelligence. Sludge, a carbon-intensive byproduct of wastewater treatment, presents both environmental challenges and opportunities for energy recovery. The paper provides a comprehensive analysis of thermal processes such as pyrolysis, gasification, co-combustion, and emerging methods, including hydrothermal carbonization and supercritical water gasification. It evaluates their carbon mitigation potential, energy efficiency, and economic feasibility, emphasizing the importance of catalyst selection, carbon dioxide capture techniques, and reactor optimization. The role of real-time monitoring via sensors and predictive modeling through artificial intelligence (AI) is highlighted as critical for enhancing process control and sustainability. Case studies and recent advances are discussed to outline future pathways for integrating thermal treatment with circular economy principles. This work contributes to sustainable waste-to-energy practices, supporting global decarbonization efforts and advancing the energy transition.

Keywords: decarbonization; sensors; sludge valorization; carbon capture; process monitoring; thermal treatment; electrical power generation



Academic Editor: Yung-Tse Hung

Received: 16 April 2025

Revised: 24 May 2025

Accepted: 25 June 2025

Published: 29 June 2025

Citation: Muniz, R.N.; Buratto, W.G.; Cardoso, R.; Barros, C.F.d.O.; Nied, A.; Gonzalez, G.V. State-of-the-Art Decarbonization in Sludge Thermal Treatments for Electrical Power Generation Considering Sensors and the Application of Artificial Intelligence. *Water* **2025**, *17*, 1946. <https://doi.org/10.3390/w17131946>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

The removal of pollutants from carbon oxidation that can occur in electricity generation processes also called decarbonization through the application of technologies such as carbon capture and storage (CCS) has different strands of technological and scientific development being researched at the level of the evaluation of constructive configurations and control of the physical and chemical variables of the reactors in the thermal processes as pyrolysis/gasification with simulations. In the decarbonization process, the carbon dioxide (CO₂) is converted to carbon monoxide (CO), which is a flammable combustion gas to produce another economic input with reforming temperature and steam, which needs to improve in large-scale plants. However, it is still unknown whether hydrogen H₂ decreased a lot in this operation of gasification/pyrolysis. This balance changed from

APÊNDICE H – TIME SERIES FORECASTING BASED ON MULTI-CRITERIA OPTIMIZATION FOR MODEL AND FILTER SELECTION APPLIED TO HYDROELECTRIC POWER PLANTS



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

Energy

journal homepage: www.elsevier.com/locate/energy



Time series forecasting based on multi-criteria optimization for model and filter selection applied to hydroelectric power plants

Rafael Ninno Muniz^a, Stefano Frizzo Stefenon^{b,c,d}, William Gouvêa Buratto^d, Ademir Nied^d, Rodolfo Cardoso^a, Cristina Keiko Yamaguchi^c, Kin-Choong Yow^b

^a Production Engineering Graduate Program, Institute of Science and Technology, Federal Fluminense University (UFF), Rio das Ostras, Brazil

^b Faculty of Engineering and Applied Sciences, University of Regina, Saskatchewan, S4S 0A2, Canada

^c Postgraduate Program in Productive Systems in Association with UNIPLAC, UNC, UNESC, and UNIVILLE, SC, Brazil

^d Systems Control Research Group, Department of Electrical Engineering, Santa Catarina State University (UDESC), Joinville, Brazil

ARTICLE INFO

Dataset link:

Keywords:

Deep learning
Hydroelectric power plants
Multi-criteria optimization
Time series forecasting

ABSTRACT

Power generation management in water-resource-based power systems depends on reservoir levels at hydroelectric power plants. Considering the advances in machine learning, forecasting inflow variation using time series could be an alternative for improving power system management. Given that there are several forecasting models and filters that can be applied, choosing one can be a challenging task, requiring experience from the designer. To solve this, multi-criteria optimization for selecting the models using the tree-structured Parzen estimator approach is proposed in this paper. The study considers the inflow data from the Belo Monte dam in Brazil. The multi-layer Elman recurrent neural network (RNN), dilated RNN, long short-term memory (LSTM), temporal fusion transformer (TFT), temporal convolutional neural (TCN), deep non-parametric time series (DeepNPTS), neural basis expansion analysis for time series (N-BEATS), and neural hierarchical interpolation for time series (NHITS) models are considered. The Christiano-Fitzgerald, Hodrick-Prescott, season-trend decomposition using locally estimated scatterplot smoothing (STL), and multiple STL filters are used. The proposed method, based on hypertuned TFT with the Hodrick-Prescott filter, had a mean absolute percentage error (MAPE) of 0.02 and a symmetric MAPE of 1.99, being superior to all the compared structures.

1. Introduction

In the Brazilian electricity system, energy dispatch is based on multi-criteria optimization that considers the capacity to generate electricity based on the level of the reservoirs [1]. Thus, the electricity system is planned with a focus on optimizing water resources over time, taking into account rainfall forecasts and reservoir levels. This optimization is based on the soil moisture accounting procedure (SMAP) model [2].

Studies have been presented with promising alternatives for river streamflow forecasting [3]. Machine learning (ML)-based models may provide superior results to classic approaches, considering their ability to handle non-linear data. The use of hybrid approaches in this context can be a solution when there is a high intensity of noise in the signal, in which filters can be applied to reduce high-frequency variations, making it possible for the model to focus on the trend of variation in the time series [4].

1.1. Research gaps

Defining which model and filter should be considered is a difficult task when designing a hybrid approach, as some techniques can significantly attenuate the signal and cause the time series to lose its characteristics; ML models that are applied to long-term forecasting may not be suitable for short-term forecasting. Considering these challenges, using a framework capable of evaluating noise attenuation filters and prediction models side by side could be an alternative to defining the appropriate prediction framework [5]. Specifically, the research gaps in existing studies are:

- Lack of a unified framework for model and filter selection: Most prior studies either focus on selecting a prediction model or

* Corresponding author.

E-mail addresses: munizrafael@id.uff.br (R.N. Muniz), stefano.frizzo.stefenon@uregina.ca (S.F. Stefenon), william.buratto@edu.udesc.br (W.G. Buratto), ademir.nied@udesc.br (A. Nied), rodolfo_cardoso@id.uff.br (R. Cardoso), cristinayamaguchi@uniplaclages.edu.br (C.K. Yamaguchi), Kin-Choong.Yow@uregina.ca (K.-C. Yow).

<https://doi.org/10.1016/j.energy.2025.138688>

Received 30 December 2024; Received in revised form 29 May 2025; Accepted 25 September 2025

Available online 30 September 2025

0360-5442/© 2025 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY-NC license (<http://creativecommons.org/licenses/by-nc/4.0/>).

APÊNDICE I – ATESTADO DE VERSÃO FINAL



UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
BIBLIOTECA UNIVERSITÁRIA
REPOSITÓRIO INSTITUCIONAL

CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT


ATESTADO DE VERSÃO FINAL

Eu, ADEMIR NIED, professor(a) do curso de Pós-graduação de Engenharia Elétrica, declaro que esta é a versão final aprovada pela comissão julgadora da dissertação/tese intitulada: **“APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA SUSTENTABILIDADE ENERGÉTICA: OTIMIZAÇÃO E PREVISÃO DE DEMANDA NA DESCARBONIZAÇÃO DE USINAS TERMELÉTRICAS DE BIOMASSA”** de autoria do(a) acadêmico WILLIAM GOUVEA BURATTO.

Joinville, 6 de abril de 2026.

Assinatura digital do(a) orientador(a):

Documento assinado digitalmente

 **ADEMIR NIED**
Data: 06/04/2026 19:13:30-0300
Verifique em <https://validar.iti.gov.br>

Professor Dr. Ademir Nied