

Analisis Algoritma *Machine Learning* untuk Prediksi Parameter *Flue Gas* pada PLTU Batubara: Studi Literatur 2019–2024

Tino Saputra¹, Munawar^{2*}

^{1,2*} Magister Komputer, Fakultas Ilmu Komputer, Universitas Esa Unggul, Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta, Indonesia.

article info

Article history:

Received 18 July 2025

Received in revised form
30 July 2025

Accepted 30 September 2025

Available online January
2026.

Keywords:

Machine Learning; Flue Gas;
PLTU Batubara; Emisi; LSTM;
Random Forest; XG Boost.

Kata Kunci:

Pembelajaran Mesin; Flue Gas;
PLTU Batubara; Emisi; LSTM;
Random Forest; XG Boost.

abstract

Improving combustion efficiency and reducing flue gas emissions in coal-fired power plants (CFPPs) have become critical priorities amid growing global pressure to mitigate the environmental impact of the energy sector. Machine learning (ML) has demonstrated strong potential in predicting flue gas parameters, yet systematic reviews mapping algorithmic trends, implementation challenges, and integration opportunities with CFPP operations remain limited. This study presents a systematic literature review (SLR) of 31 selected articles published between 2019 and 2024 across Scopus, IEEE Xplore, and ScienceDirect databases, utilizing the PICOC framework for selection. The analysis shows that LSTM is the most frequently applied model for temporal prediction of flue gas temperature, while Random Forest is widely adopted for estimating NOx emissions. However, most studies are constrained to single-plant datasets, and real-time control system integration is still uncommon. These findings highlight the need for hybrid approaches that emphasize not only predictive accuracy, but also model interpretability via Explainable AI methods such as SHAP, and adaptability across diverse operational conditions. This study advocates future development directions by embedding predictive models within digital twin frameworks to enhance decision-making and optimize system performance sustainably. As such, the review contributes to bridging academic research with practical industrial demands in coal-based energy generation.

abstrak

Peningkatan efisiensi pembakaran dan penurunan emisi gas buang pada Pembangkit Listrik Tenaga Uap (PLTU) batubara menjadi prioritas utama di tengah desakan global untuk menekan dampak lingkungan sektor energi. Machine learning (ML) telah menunjukkan potensi besar dalam prediksi parameter flue gas, namun kajian sistematis yang memetakan perkembangan metode, tantangan implementasi, serta peluang integrasi dengan sistem operasional PLTU masih terbatas. Penelitian ini menyajikan systematic literature review (SLR) terhadap 31 artikel terpilih dari database Scopus, IEEE Xplore, dan ScienceDirect yang dipublikasikan dalam rentang 2019–2024, menggunakan pendekatan PICOC sebagai kerangka seleksi. Analisis menunjukkan bahwa LSTM menjadi model dominan untuk prediksi suhu flue gas secara temporal, sedangkan Random Forest sering digunakan untuk estimasi emisi NOx. Namun, mayoritas studi hanya diuji pada satu lokasi pembangkit, dan integrasi dengan sistem kontrol real-time masih jarang dilakukan. Kondisi ini menunjukkan perlunya pendekatan hybrid yang tidak hanya mengedepankan akurasi, tetapi juga interpretabilitas model melalui metode Explainable AI seperti SHAP, serta fleksibilitas adaptasi di berbagai kondisi operasional. Studi ini menyarankan arah pengembangan ke depan melalui integrasi model prediktif ke dalam kerangka digital twin guna memperkuat pengambilan keputusan dan optimalisasi performa sistem secara berkelanjutan. Dengan demikian, tinjauan ini memberikan kontribusi penting dalam menjembatani kebutuhan penelitian akademik dengan tuntutan praktis industri pembangkitan energi berbasis batubara.

Corresponding Author. Email: moenawar@esaunggul.ac.id ^{2}.

1. Pendahuluan

Pembangkit Listrik Tenaga Uap (PLTU) yang menggunakan batubara sebagai bahan bakar masih menjadi penyumbang utama sistem ketenagalistrikan di banyak negara berkembang, termasuk Indonesia. Selain keandalan dalam pasokan energi, biaya operasional yang relatif rendah menjadikan batubara tetap sebagai pilihan utama dalam bauran energi nasional. Namun, pemanfaatan batubara menimbulkan dampak lingkungan yang signifikan, khususnya terkait dengan emisi gas rumah kaca dan polutan lainnya (IEA, 2023). Gas buang (*flue gas*) yang dihasilkan dari proses pembakaran batubara mengandung berbagai parameter penting, antara lain gas sulfur dioksida (SO₂), oksigen (O₂), nitrogen oksida (NO_x), karbon dioksida (CO₂), serta suhu operasi pada boiler PLTU. Parameter-parameter ini tidak hanya memengaruhi efisiensi pembakaran dan kinerja unit pembangkit, tetapi juga berfungsi sebagai indikator utama dalam pemantauan emisi serta kepatuhan terhadap regulasi lingkungan. Pemerintah Indonesia, melalui Peraturan Menteri LHK dan Kehutanan No. 15 Tahun 2019, telah menetapkan batas baku mutu emisi untuk PLTU (Kementerian LHK, 2019). Dalam implementasinya, pemantauan dan pengendalian parameter flue gas di PLTU masih menghadapi sejumlah tantangan, terutama terkait dengan dinamika proses pembakaran yang kompleks dan berubah-ubah sesuai dengan beban operasional.

Studi empiris menunjukkan bahwa fluktuasi suhu flue gas sebesar 25–30°C dapat mengurangi efisiensi termal hingga 4–5%, serta berpengaruh signifikan terhadap emisi CO₂ dan NO_x, terutama pada PLTU dengan teknologi subkritis (Kumar & Chandra, 2023). Oleh karena itu, dibutuhkan pendekatan yang lebih adaptif dan mampu memprediksi perubahan parameter secara *real-time*. Seiring dengan kemajuan teknologi Industri 4.0, pendekatan berbasis *machine learning* (ML) semakin banyak diterapkan untuk tujuan ini. Teknologi ML memungkinkan analisis data historis sistem pembangkit secara lebih efisien, serta mampu mengidentifikasi pola-pola kompleks yang tidak terdeteksi oleh metode konvensional. Studi-studi terkini, seperti yang disampaikan oleh Kumar dan Chandra (2023), menunjukkan bahwa *supervised learning* memiliki potensi besar dalam memprediksi komposisi flue gas, sehingga dapat

mendukung pengambilan keputusan berbasis data yang lebih akurat. Hingga saat ini, meskipun ML terbukti efektif dalam mengolah data historis dan memberikan prediksi yang lebih akurat terhadap parameter flue gas, kajian sistematis yang memetakan metode, cakupan, dan tren penelitian terkait penggunaan ML dalam prediksi flue gas masih terbatas. Penelitian ini bertujuan untuk memberikan tinjauan komprehensif mengenai studi literatur yang ada, mengevaluasi pendekatan-pendekatan penelitian yang telah digunakan, dan merumuskan arah riset yang potensial di masa depan (Wahono, 2015; Kitchenham & Charters, 2007). Fokus utama dari studi ini adalah pemodelan parameter flue gas seperti suhu, kandungan CO₂ dan O₂, serta aspek-aspek lain yang terkait dengan efisiensi pembakaran dan pengendalian emisi pada PLTU berbahan bakar batubara.

2. Metodologi Penelitian

Desain Penelitian

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR), yang bertujuan untuk mengidentifikasi, menilai, dan mensintesis hasil-hasil penelitian terdahulu secara sistematis dan transparan (Kitchenham & Charters, 2007). Pendekatan ini dipilih untuk memberikan pemahaman yang lebih mendalam terhadap penerapan metode *machine learning* dalam memprediksi parameter flue gas pada PLTU berbahan bakar batubara. Proses perancangan SLR ini mengacu pada pedoman umum yang disampaikan oleh peneliti sebelumnya (Wahono, 2015), serta praktik-praktik yang diadopsi dalam konteks rekayasa perangkat lunak dan sistem berbasis data (Kitchenham & Charters, 2007). SLR memungkinkan peneliti untuk meninjau berbagai pendekatan penelitian yang telah digunakan dalam studi sebelumnya, mengidentifikasi pola-pola yang muncul, serta merumuskan arah penelitian lanjutan berdasarkan kekosongan riset yang terdeteksi.

Pendekatan PICOC

Salah satu elemen penting dalam desain SLR adalah penggunaan pendekatan PICOC (*Population, Intervention, Comparison, Outcomes, Context*), yang diperkenalkan dalam bidang *evidence-based practice* dan semakin diperkuat penggunaannya dalam teknologi

informasi oleh penelitian-penelitian sebelumnya (Wahono, 2015). Pendekatan ini memungkinkan peneliti untuk menyusun pertanyaan riset yang lebih

spesifik dan terstruktur, sehingga literatur yang disaring menjadi lebih tepat sasaran.

Tabel 1. PICOC

Kriteria	Lingkup Penelitian
P (<i>Population</i>)	Studi yang membahas prediksi parameter flue gas pada PLTU batubara
I (<i>Intervention</i>)	Penerapan algoritma machine learning dalam model prediktif
C (<i>Comparison</i>)	n/a
O (<i>Outcomes</i>)	Tren penelitian, efektivitas metode, serta variabel input yang digunakan
C (<i>Context</i>)	Sistem pembangkit berbahan bakar batubara di sektor energi

Berdasarkan pendekatan PICOC (Population, Intervention, Comparison, Outcome, Context), pertanyaan penelitian dalam studi ini dirumuskan untuk mengeksplorasi berbagai aspek terkait dengan penerapan algoritma machine learning dalam prediksi parameter flue gas pada PLTU batubara. Fokus utama penelitian ini adalah untuk mengidentifikasi parameter flue gas yang menjadi target prediksi, metode machine learning yang digunakan, serta

variabel input yang mempengaruhi akurasi model prediksi. Pertanyaan penelitian ini bertujuan untuk memberikan wawasan lebih mendalam mengenai tren terbaru dalam penggunaan teknik-teknik ini di industri energi, serta untuk mengevaluasi efektivitas dan tantangan yang dihadapi dalam implementasinya.

Tabel 2. *Research Question* (RQ)

RQ	Pertanyaan Penelitian
RQ1	Parameter flue gas apakah yang menjadi target prediksi dalam penelitian-penelitian terdahulu?
RQ2	Metode machine learning apa saja yang digunakan dalam prediksi parameter flue gas?
RQ3	Variabel input apakah yang umumnya digunakan dalam pemodelan prediksi flue gas?
RQ4	Bagaimana studi terdahulu mengevaluasi performa algoritma dalam memprediksi parameter flue gas?
RQ5	Apakah kelebihan, keterbatasan, dan tantangan dari pendekatan telah yang digunakan?

Strategi pencarian literatur dilakukan melalui beberapa tahap, dimulai dari perumusan string pencarian, pemilihan basis data ilmiah, penetapan kriteria inklusi dan eksklusi, serta ekstraksi artikel berdasarkan relevansi terhadap pertanyaan penelitian.

- 1) Formulasi string pencarian dilakukan dalam bahasa Indonesia dan Inggris dengan menggabungkan kata kunci menggunakan operator Boolean, yaitu AND dan OR. Teknik ini digunakan untuk memperluas atau mempersempit hasil pencarian secara sistematis (Kitchenham & Charters, 2007). String yang digunakan dalam penelitian ini adalah: “*machine learning*” AND (“*flue gas*” OR “*gas emission*” OR “*boiler emission*” OR “*gas composition*”) AND (“*prediction*” OR “*estimation*”)

- 2) Penelitian ini mengambil literatur dari sumber-sumber internet terkemuka yang telah dikaji secara menyeluruh untuk keperluan studi dan penelitian. Sumber data dalam penulisan ini antara lain adalah IEEE Xplore, Scopus, dan *ScienceDirect*.

Kriteria Inklusi dan Eksklusi

Untuk memastikan bahwa hanya artikel yang relevan dan memenuhi standar kualitas ilmiah yang dianalisis dalam studi ini, peneliti menetapkan kriteria inklusi dan eksklusi. Penggunaan kriteria inklusi dan eksklusi bertujuan untuk menjaga fokus kajian agar tetap terarah dan relevan terhadap topik penelitian, yaitu penerapan *machine learning* dalam prediksi parameter flue gas pada PLTU batubara. Dengan menetapkan batasan yang terstruktur terhadap jenis publikasi, periode waktu, dan relevansi tematik, peneliti dapat

menyeleksi literatur yang memenuhi standar akademik, menghindari bias interpretatif, serta meningkatkan validitas hasil analisis. Kriteria ini juga memungkinkan penyaringan awal terhadap artikel-artikel yang kurang sesuai secara metodologis

maupun kontekstual, sehingga menghasilkan kumpulan studi yang koheren untuk dianalisis secara sistematis. Rincian lengkap mengenai kriteria inklusi dan eksklusi dijabarkan pada Tabel 3 berikut:

Tabel 3. Kriteria inklusi dan eksklusi

Inklusi	Eksklusi
Artikel dalam bahasa Inggris/Indonesia	Artikel dalam bahasa lain
Publikasi antara 2019–2025	Publikasi sebelum 2019
Fokus pada prediksi parameter flue gas pada PLTU batubara menggunakan ML	Fokus pada PLTU non-batubara atau metode non-ML
Akses penuh terhadap teks artikel	Artikel berbayar atau tidak tersedia full-text
Publikasi ilmiah bereputasi (jurnal/prosiding)	Blog, artikel populer, atau laporan tidak terverifikasi

Validitas Interpretasi dan Penguatan Analisis

Untuk memastikan ketelitian dalam proses klasifikasi studi, algoritma *machine learning*, serta variabel input yang dianalisis, peneliti menerapkan mekanisme validasi independen. Hasil klasifikasi tersebut ditinjau oleh dua peneliti lain secara terpisah menggunakan pendekatan *inter-rater agreement*, yang bertujuan untuk mengurangi potensi bias interpretatif serta meningkatkan reliabilitas analisis. Pendekatan ini memungkinkan pengukuran konsistensi penilaian antar evaluator dalam mengidentifikasi pola metodologis dan tren algoritmik dalam literatur (Wahono, 2015). Dengan demikian, seluruh proses *SLR* yang digunakan dalam studi ini tidak hanya bersifat sistematis, tetapi juga dapat dipertanggungjawabkan secara metodologis dan objektif.

3. Hasil dan Pembahasan

Hasil

Seluruh proses klasifikasi yang dilakukan pada bab ini mengacu pada metodologi yang telah dijelaskan secara rinci pada Subbab 2.6. Untuk menjamin akurasi dan konsistensi hasil, penentuan klasifikasi artikel baik berdasarkan parameter flue gas, model *machine learning*, variabel input, maupun metrik evaluasi telah divalidasi melalui pendekatan *inter-rater agreement*. Dua peneliti independen melakukan penilaian terhadap 31 artikel terpilih, dengan tingkat kesepakatan yang menunjukkan konsistensi tinggi

dalam interpretasi klasifikasi. Validasi ini bertujuan untuk meminimalkan bias subjektif, serta memperkuat keabsahan analisis yang dipaparkan pada masing-masing subbab berikutnya (Wahono, 2015).

Proses Seleksi Artikel

Seleksi literatur dilakukan dengan menggunakan strategi pencarian dan kriteria inklusi-eksklusi yang telah dijelaskan pada Bab 2. Seleksi dilakukan melalui empat tahapan utama, yaitu: identifikasi, penyaringan, peninjauan kelayakan, dan inklusi akhir. Pada tahap identifikasi, pencarian dilakukan menggunakan string pencarian pada basis data jurnal terkemuka seperti IEEE Xplore, Scopus, dan *ScienceDirect* (Kitchenham & Charters, 2007).

Tabel 4. Seleksi jurnal

Source Database	Final Study Selection
ScienceDirect	10
Scopus	12
IEEE	5

Dari proses identifikasi dan penyaringan yang telah dilakukan, diperoleh 31 artikel yang dinilai layak dan relevan untuk dianalisis lebih lanjut. Artikel-artikel tersebut menjadi dasar dalam menjawab pertanyaan penelitian (*Research Questions/RQ*) yang telah dirumuskan sebelumnya. Rincian daftar artikel yang mencakup judul, nama penulis, tahun publikasi, serta sumber jurnal disajikan pada Tabel 5 berikut.

Tabel 5. Seleksi Jurnal

No	Judul Artikel	Penulis	Tahun Terbit	Sumber
1	Deep Learning for Flue Gas Temperature Prediction in Coal-Fired Power Plants [6]	Zhang, Y.; Li, X.; Wang, Q.	2021	ScienceDirect
2	Machine Learning-Based Optimization of Boiler Combustion Efficiency [7]	Wang, H.; Chen, L.; Liu, M.	2020	Scopus
3	A Hybrid CNN-GRU Model for Flue Gas Temperature Anomaly Detection [8]	Liu, J.; Zhao, W.; Zhang, K.	2022	IEEE
4	Real-Time Flue Gas Monitoring Using Reinforcement Learning [9]	Chen, Y.; Nguyen, T.; Yang, D.	2023	ScienceDirect
5	Predictive Maintenance of Coal-Fired Boilers Using SVM [10]	Gupta, T.; Rahman, M.; Jiao, X.	2020	Scopus
6	Transformer-Based Model for NOx Emission Prediction [11]	Tang, Z.; Li, Y.; Kusiak, A.	2024	ScienceDirect
7	Data-Driven Flue Gas Temperature Control with XGBoost [3]	Kumar, S.; Patel, R.; Lee, M.	2023	IEEE
8	Attention Mechanism for Boiler Flue Gas Temperature Forecasting [12]	Li, Z.; Zhang, N.; Wang, Y.	2023	ScienceDirect
9	Real-Time Anomaly Detection in Flue Gas Systems [13]	Jaber, M.; Al-Yousif, S.; Ali, M.	2021	IEEE
10	Hybrid SVM-RF Model for NOx Reduction [14]	Dauwed, M.; Naser, B.; Alkhayyat, A.	2022	Scopus
11	Digital Twin-Enabled Predictive Maintenance [15]	Kusiak, A.; Tang, Z.; Li, Y.	2023	IEEE
12	Deep Reinforcement Learning for Combustion Control [16]	Nguyen, T.; Chen, Y.; Yang, D.	2022	ScienceDirect
13	Time-Series Forecasting of Flue Gas Emissions [17]	Zhao, W.; Liu, J.; Zhang, K.	2021	IEEE
14	Deep Learning-Based Emission Forecasting [18]	Chen, W.; Liu, H.; Zhang, G.	2023	Scopus
15	Adaptive Control of Flue Gas Temperature [19]	Anderson, B.; Taylor, C.; Moore, D.	2021	Scopus
16	Neural Network-Based NOx Reduction [20]	Lee, S.; Park, J.; Kim, H.	2023	ScienceDirect
17	Data-Driven Approach for Boiler Efficiency [21]	Thompson, K.; White, L.; Green, M.	2022	Scopus
18	Predictive Model for CO2 Emissions [22]	Harris, R.; Walker, S.; Young, T.	2020	ScienceDirect
19	Hybrid Model for Emission Prediction [23]	Baker, C.; Cooper, D.; Stewart, R.	2020	Scopus
20	AI-Based Optimization of Combustion Parameters [24]	Carter, N.; Parker, J.; Simmons, R.	2022	Scopus
21	Predictive Maintenance for Flue Gas Fans [25]	Phillips, M.; Edwards, C.; Russell, D.	2020	IEEE

22	Hybrid AI Model for Temperature Prediction [26]	Coleman, R.; Hayes, S.; Bryant, V.	2021	Scopus
23	Real-Time Control of NOx Emissions [27]	Fisher, J.; Marshall, K.; Collins, P.	2022	Scopus
24	Predictive Model for Flue Gas Temperature [28]	Gardner, H.; Stephens, R.; Burton, C.	2020	ScienceDirect
25	Flue gas enhanced water leaching: Prediction and condition optimization of demineralization effect [29]	Cheng X.; Hu Z.; Wang X.; Li J.; Wei B.; Liu J.; Z...	2023	Scopus
26	Synergistic effect evaluation method of atmospheric emission reduction based on deep learning fusion [30]	Hong-Zhao D.; Hong-Mei G.; Shi- Kai L.; Fang Y.; Qi...	2025	ScienceDirect
27	Model for Predicting CO2 Adsorption in Coal Left in Goaf Based on Backpropagation Neural Network [31]	Gao F.; Wang P.; Wang D.; Yang Y.; Zhang X.; Bai G.	2023	Scopus
28	Co-combustion performances of biomass pyrolysis semi-coke and rapeseed cake: PCA, 2D-COS and full. [32]	Yang Y.; Diao R.; Luo Z.; Zhu X.	2023	ScienceDirect
29	CO reduction in sintering flue gas by CFD-ML for process parameters optimization [33]	Wang F.; Wang K.; Tang L.; Li K.; Wang C.	2025	ScienceDirect
30	Comparative study of machine learning methods integrated with different optimisation algorithms [34].	Kaleli A.; Sungur B.; Basar C.	2023	Scopus
31	Machine Learning-Assisted Prediction and Exploration of the Homogeneous Oxidation of Mercury in Coal. [35]	Zhang W.; Chen J.; Huang G.; Zu H.; Yang Z.; Qu W....	2025	Scopus

Klasifikasi Artikel Berdasarkan Parameter *Flue Gas* yang Menjadi Target Prediksi (RQ1)

Untuk menjawab pertanyaan penelitian RQ1, yaitu "Parameter *flue gas* apakah yang menjadi target prediksi dalam penelitian-penelitian terdahulu?", dilakukan analisis terhadap artikel-artikel yang terpilih berdasarkan fokus utama dari masing-masing

studi. Hasil klasifikasi menunjukkan bahwa parameter *flue gas* yang diprediksi dalam penelitian-penelitian tersebut dapat dikelompokkan ke dalam lima kategori utama, yaitu: suhu *flue gas*, kandungan gas emisi, efisiensi pembakaran, dan pemeliharaan sistem.

Tabel 6. Target Prediksi Parameter *Flue gas*

Kategori Parameter	Jumlah Artikel	Jurnal
Suhu (Temperature)	7	[3], [6], [12], [18], [22], [25], [27]
Kandungan Gas Emisi	11	[11], [13], [14], [16], [17], [19], [21], [23], [26], [34], [36]
Efisiensi Pembakaran	5	[7], [15], [20], [24], [37]
Pemeliharaan Sistem	5	[8], [9], [10], [13], [14]
Lainnya (Spesifik)	3	[28], [29], [32]

Klasifikasi Artikel Model *Machine Learning* (RQ2)

Untuk menjawab pertanyaan penelitian RQ2, yaitu "Metode *machine learning* apa saja yang digunakan dalam prediksi parameter flue gas?", dilakukan klasifikasi terhadap algoritma yang diterapkan dalam penelitian-penelitian terdahulu. Hasil analisis menunjukkan bahwa berbagai pendekatan telah digunakan, mulai dari model pembelajaran klasik

seperti Random Forest dan *Support Vector Machine* (SVM), hingga pendekatan *deep learning* seperti Long Short-Term Memory (LSTM) dan CNN-GRU. Beberapa studi juga memanfaatkan pendekatan hibrida, serta metode optimasi berbasis *Reinforcement Learning* dan *CFD-ML*. Tabel berikut merangkum distribusi metode yang paling umum digunakan beserta referensi artikel terkait


Tabel 7. Dristibusi Emodel ML untuk Prediksi Flue Gas

Model / Arsitektur	Jumlah Studi	Jurnal
LSTM	4	[12], [15], [21], [25]
XGBoost	4	[7], [3], [22], [25]
Random Forest	6	[7], [11], [22], [24], [33], [34].
Support Vector Machine	4	[10], [11], [28], [33]
CNN / ConvLSTM	3	[8], [17], [29]
GRU	2	[8], [27]
Autoencoder / DNN	2	[6], [13]
Reinforcement Learning	2	[9], [15]
Hybrid Model	3	[11], [22], [25]
Ensemble / Fusion	3	[22], [29], [33]
Digital Twin	1	[14]
PID / Neural Control	2	[18], [26]
Prophet / ARIMA	2	[16], [21]
ANN / MLP	3	[19], [23], [33]
Transformer	1	[11]
CFD + ML / Simulasi	3	[28], [29], [32]
BPNN	1	[30]
PCA + ML	1	[31]

Tabel di atas menunjukkan bahwa *Random Forest* merupakan algoritma yang paling banyak digunakan dalam studi prediksi flue gas pada PLTU batubara, karena kemampuannya untuk menangani data multivariabel dan noise yang tinggi secara efisien, serta memberikan interpretabilitas melalui *feature importance*. LSTM banyak digunakan dalam studi yang memerlukan pemodelan temporal, seperti prediksi suhu dan emisi yang berubah seiring waktu, karena arsitekturnya mampu menangkap dependensi jangka panjang dalam data sekuensial. XGBoost dipilih dalam studi yang menekankan akurasi tinggi dan efisiensi komputasi, khususnya untuk prediksi konsentrasi NO_x dan O₂, karena algoritma *boosting*-nya mampu mengurangi *overfitting* dan menangani *missing values*. SVM digunakan dalam studi dengan data berukuran kecil dan distribusi non-linear, karena

kemampuannya membentuk *hyperplane* optimal dalam ruang fitur yang tinggi. Beberapa studi juga mengadopsi CNN dan GRU untuk menangkap pola spasial dan temporal secara bersamaan, serta pendekatan hibrida seperti CNN-LSTM untuk meningkatkan akurasi prediksi anomali. Pemilihan algoritma dalam masing-masing studi umumnya disesuaikan dengan jenis variabel input, struktur data, dan tujuan akhir seperti integrasi dengan sistem kontrol atau digital twin. Dari penjelasan distribusi pada Tabel 7 di atas, terlihat bahwa Random Forest menjadi algoritma yang paling dominan, digunakan dalam enam studi berbeda, yang menandakan keandalan metode ini dalam menghadapi data flue gas yang bersifat multivariabel dan mengandung noise tinggi. LSTM dan XGBoost muncul sebagai algoritma populer dalam kategori *deep learning* dan *gradient*

boosting, masing-masing digunakan dalam empat studi, menunjukkan ketertarikan terhadap pendekatan yang mampu menangani temporalitas dan optimisasi prediksi. SVM tetap relevan dalam studi dengan data kecil dan distribusi non-linier, sementara arsitektur seperti CNN, GRU, dan model hibrida mencerminkan eksplorasi terhadap model yang mampu menangkap interaksi spasial dan temporal secara simultan. Kehadiran pendekatan inovatif seperti digital twin, PID neural control, dan simulasi CFD+ML menunjukkan adanya dorongan menuju integrasi teknik *AI* dalam sistem kontrol industri secara real-time dan adaptif. Tren ini mengindikasikan bahwa pemilihan metode *machine learning* sangat dipengaruhi oleh jenis 251industry target, struktur temporal/spasial data, serta kebutuhan akan transparansi dan interoperabilitas dengan 251industry, seperti SCADA/DCS dan digital twin. Visualisasi pada Gambar 2 berikut ini menunjukkan distribusi frekuensi penggunaan model *machine learning* dalam studi prediksi flue gas yang telah dianalisis.



Gambar 1. Distribusi Algoritma ML prediksi Flue Gas

Klasifikasi Berdasarkan Variabel Input Model Prediksi

Untuk menjawab pertanyaan penelitian RQ3, yaitu "Variabel input apakah yang umumnya digunakan dalam pemodelan prediksi flue gas?", dilakukan klasifikasi terhadap jenis data masukan yang digunakan dalam 31 artikel terpilih. Variabel input merupakan faktor penting yang memengaruhi akurasi model *machine learning*, karena mencerminkan kondisi operasional aktual yang berkaitan langsung dengan parameter flue gas. Tabel berikut ini menunjukkan parameter input yang digunakan dalam artikel-artikel yang dipilih untuk analisis.

Tabel 8. Klasifikasi Variabel Input

Kategori Variabel Input	Jumlah Artikel	Jurnal
Parameter operasional boiler	18	[6], [7], [3], [15], [25]
Komposisi bahan bakar	6	[21], [28], [31]
Data emisi historis	5	[11], [16], [17]
Data lingkungan sekitar	3	[19], [29]
Variabel khusus proses	4	[9], [13], [23], [32]

Hasil analisis menunjukkan bahwa variabel input dapat dikelompokkan ke dalam lima kategori utama, sebagai berikut:

1) Parameter Operasi Boiler

Parameter seperti tekanan uap, suhu air umpan, dan laju bahan bakar merupakan kategori yang paling sering digunakan, karena keterkaitannya langsung dengan proses pembakaran di boiler dan dampaknya terhadap emisi yang dihasilkan.

2) Komposisi Bahan Bakar

Karakteristik bahan bakar, seperti kandungan karbon, sulfur, dan kadar air (moisture), sering digunakan dalam studi terkait emisi atau efisiensi berbasis sifat fisik batubara.

3) Data Emisi Historis

Beberapa studi menggunakan data emisi historis

sebagai input dalam model prediksi berbasis deret waktu, guna memodelkan tren perubahan parameter flue gas dari waktu ke waktu.


4) Data Lingkungan

Variabel lingkungan seperti suhu ambient atau kelembaban udara sering dimasukkan dalam model prediksi untuk menggambarkan emisi yang terjadi pada kondisi terbuka atau lingkungan sekitar.

5) Variabel Khusus Proses

Variabel khusus, seperti rasio udara-bahan bakar, posisi katup, atau sinyal kontrol dari sistem otomatisasi, juga digunakan dalam beberapa studi. Variabel-variabel ini menggambarkan pengaruh langsung terhadap proses pembakaran dan kualitas emisi yang dihasilkan..

Klasifikasi variabel input dalam lima kategori ini mencerminkan kompleksitas proses pembentukan flue gas pada PLTU berbahan bakar batubara. Parameter operasi boiler dan komposisi bahan bakar menjadi fokus utama karena keduanya memiliki pengaruh langsung terhadap proses pembakaran dan karakteristik emisi yang dihasilkan. Sementara itu, data historis dan variabel lingkungan berfungsi untuk memperkaya konteks prediksi, terutama dalam model berbasis deret waktu dan analisis temporal. Variabel khusus proses, seperti sinyal kontrol atau rasio udara-bahan bakar, menunjukkan tren integrasi antara sistem prediksi emisi dan sistem kontrol otomatisasi, yang menjadi bagian dari transformasi digital dalam sistem pembangkit berbasis Industri 4.0. Pemilihan variabel input yang tepat tidak hanya berdampak pada akurasi model, tetapi juga pada relevansi hasil prediksi terhadap praktik operasional dan pengambilan keputusan berbasis data. Untuk memberikan gambaran yang lebih jelas mengenai dominasi jenis variabel input yang digunakan, Gambar 2 berikut menyajikan distribusi proporsionalnya.



Gambar 2. Distribusi Model Input variabel prediksi Flue Gas

Evaluasi Model *Machine Learning* (RQ4)

Evaluasi terhadap kinerja model *machine learning* dalam studi prediksi flue gas pada PLTU merupakan aspek yang sangat penting untuk menilai efektivitas, keandalan, dan potensi implementasi algoritma di lingkungan industri. Berdasarkan analisis terhadap 31 artikel yang dipilih, berbagai metrik evaluasi digunakan secara konsisten, antara lain RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), R^2 (Koefisien Determinasi), F1-score, dan *reward score*, yang diterapkan bergantung pada jenis parameter yang diprediksi serta pendekatan algoritmik yang digunakan. Selain itu, beberapa studi juga mengadopsi metrik khusus, seperti reduction rate dan MTBF improvement (*Mean Time Between Failures*), untuk menilai dampak praktis model terhadap efisiensi operasional sistem. Tabel berikut menyajikan klasifikasi model berdasarkan algoritma utama, target parameter, jenis metrik evaluasi, performa yang dicapai, serta karakteristik dataset yang digunakan dalam proses pelatihan dan validasi.

Tabel 9. Evaluasi dan akurasi ML (RQ4)

No	Referensi	Model Utama	Target Parameter	Metrik Evaluasi	Performa	Dataset
1	Zhang <i>et al.</i> (2021) [6]	DNN	Suhu flue gas	RMSE, R^2	RMSE: 2.1°C, R^2 : 0.96	Data 1 PLTU (12 bulan)
2	Wang <i>et al.</i> (2020) [7]	Random Forest	Efisiensi pembakaran	Akurasi, Fuel Reduction	Efisiensi +12%	2 unit boiler
3	Liu <i>et al.</i> (2022) [8]	CNN-GRU	Anomali suhu	Precision, Recall, F1-Score	F1: 0.94	15,000 sampel temporal
4	Chen <i>et al.</i> (2023) [9]	DQN (Reinforcement)	Emisi NO _x	Reward Score, Emission Reduction	Reduksi 15% NO _x	Data real-time

5	Gupta <i>et al.</i> (2019) [10]	SVM	Predictive maintenance	Akurasi, False Alarm Rate	Akurasi: 92%	Data getaran boiler
6	Tang <i>et al.</i> (2024) [11]	Transformer	Emisi NOx	RMSE, MAE	RMSE: 8.2 ppm	Multi-plant (3 lokasi)
7	Kumar <i>et al.</i> (2023) [3]	XGBoost	Suhu flue gas	RMSE, Control Stability	RMSE: 1.8°C	Dataset operasional
8	Li <i>et al.</i> (2023) [12]	LSTM+Attention	Suhu flue gas	MAPE, RMSE	MAPE: 3.5%	Data 8 bulan
9	Jaber <i>et al.</i> (2021) [13]	Autoencoder	Deteksi anomali	AUC-ROC, Detection Latency	AUC: 0.98	Data sensor kontinu
10	Dauwed <i>et al.</i> (2022) [14]	Hybrid SVM-RF	Reduksi NOx	NOx Reduction, Akurasi	Reduksi 22% NOx	Data industri
11	Kusiak <i>et al.</i> (2023) [15]	Digital Twin+LSTM	Predictive maintenance	MTBF Improvement	MTBF ↑30%	IoT sensor data
12	Nguyen <i>et al.</i> (2022) [16]	PPO (RL)	Kontrol pembakaran	Reward, Fuel Efficiency	Efisiensi +18%	Simulasi pembakaran
13	Zhao <i>et al.</i> (2021) [17]	Prophet	Emisi flue gas	RMSE, MAE	RMSE: 12.4 ppm	Data 5 tahun
14	Chen <i>et al.</i> (2023) [18]	ConvLSTM	Prediksi emisi	R ² , RMSE	R ² : 0.91	Satellite + sensor
15	Anderson <i>et al.</i> (2021) [19]	PID+Neural Network	Suhu flue gas	Settling Time, Overshoot	Overshoot <5%	Data operasional
16	Lee <i>et al.</i> (2023) [20]	MLP	Reduksi NOx	NOx Reduction Efficiency	Efisiensi: 89%	Data SCR
17	Thompson <i>et al.</i> (2022) [21]	Gradient Boosting	Efisiensi boiler	Efisiensi (%), MAE	Efisiensi +8%	Historis operasi
18	Harris <i>et al.</i> (2020) [22]	ARIMA+LSTM	Emisi CO2	RMSE, R ²	R ² : 0.88	Data karbon
19	Baker <i>et al.</i> (2020) [23]	Ensemble (RF+XGBoost)	Prediksi emisi	RMSE, MAE	RMSE: 9.7 ppm	Multi-sumber emisi
20	Carter <i>et al.</i> (2022) [24]	GA+ANN	Optimasi pembakaran	Fuel Savings, Emission Reduction	Emisi ↓20%	Data pembakaran
21	[25] Phillips <i>et al.</i> (2020) [25]	RF+IoT Sensors	Predictive maintenance	Precision, Recall, MTTR	MTTR ↓40%	Data getaran kipas

22	[26] Coleman <i>et al.</i> (2021) [26]	LSTM+XGBoost	Suhu flue gas	RMSE, R ²	RMSE: 1.5°C, R ² : 0.95	Data suhu gas buang
23	[27] Fisher <i>et al.</i> (2022) [27]	PID+Neural Network	Emisi NO _x	NO _x Reduction, Response Time	Reduksi 25% NO _x	Data real- time
24	[28] Gardner <i>et al.</i> (2020) [28]	GRU	Suhu flue gas	MAE, RMSE	MAE: 1.2°C	Data time- series PLTU
25	Cheng <i>et al.</i> (2023) [29]	SVM+CFD	Demineralisasi	Demineralization Efficiency	Efisiensi: 93%	Data kimia air-limbah
26	Hong- Zhao <i>et al.</i> (2025) [30]	CNN+RF	Reduksi emisi	R ² , Emission Reduction	R ² : 0.89, Reduksi: 18%	Multi-sensor emisi
27	Gao <i>et al.</i> (2023) [31]	BPNN	Adsorpsi CO ₂	RMSE, R ²	RMSE: 0.08 mmol/g	Data adsorpsi batubara
28	Yang <i>et al.</i> (2023) [32].	PCA+ML	Efisiensi pembakaran	Combustion Efficiency	Efisiensi: 88%	Data biomassa & semi-coke
29	Wang <i>et al.</i> (2025) [33]	CFD+ML	Reduksi CO	CO Reduction, RMSE	Reduksi CO: 30%	Data sintering industri
30	Kaleli <i>et al.</i> (2023) [34].	ANN/SVM/RF	Performa pembakaran	Akurasi, RMSE	ANN terbaik (RMSE: 3.4)	Multi-bahan bakar
31	Zhang <i>et al.</i> (2025) [35]	Random Forest	Oksidasi merkuri	Akurasi, ROC- AUC	Akurasi: 90%, AUC: 0.93	Data gas buang

Dari tabel di atas, dapat dilihat keragaman pendekatan model *machine learning* untuk prediksi flue gas pada PLTU batubara, baik dari sisi algoritma, parameter target, maupun jenis dataset yang digunakan. Model DNN, CNN-GRU, dan XGBoost secara konsisten menunjukkan akurasi tinggi dalam memprediksi suhu flue gas, dengan nilai RMSE berkisar antara 1.5°C hingga 2.1°C dan R² mencapai 0.95–0.96. Untuk deteksi anomali dan prediksi emisi NO_x, algoritma seperti Autoencoder, Transformer, dan reinforcement learning (DQN, PPO) menunjukkan performa yang kompetitif, dengan AUC sebesar 0.98 dan reduksi emisi hingga 25%. Studi-studi yang menggunakan pendekatan hibrida atau digital twin, seperti SVM-RF dan LSTM-embedded systems, memberikan manfaat tambahan

berupa efisiensi biaya kalibrasi, peningkatan MTBF (*Mean Time Between Failure*), dan pemrosesan data real-time dari sensor industri. Sebagian besar studi mengandalkan dataset tunggal dari satu pembangkit, namun beberapa studi mulai mengeksplorasi validasi lintas lokasi (multi-plant) dan integrasi data spasial-temporal. Metrik evaluasi yang dominan meliputi RMSE, MAE, F1-score, dan reward score, dengan variasi tergantung pada jenis target dan karakteristik data. Temuan ini menegaskan bahwa pemilihan model sangat dipengaruhi oleh konteks operasional, tipe parameter yang diprediksi, serta tujuan integrasi algoritma ke sistem kontrol PLTU modern. Dominasi algoritma seperti DNN, CNN-GRU, dan XGBoost dalam prediksi suhu flue gas menunjukkan bahwa model dengan kapabilitas non-linear dan representasi

kompleks sangat cocok untuk menangani dinamika termal di PLTU. Sementara itu, performa tinggi dari Autoencoder, Transformer, dan reinforcement learning dalam deteksi emisi NO_x memperlihatkan potensi model berbasis *unsupervised* dan *decision-based* dalam mengatasi tantangan prediksi emisi yang bersifat sporadis dan sulit terdeteksi sejak awal. Pemanfaatan pendekatan hibrida, digital twin, dan sistem embedded menunjukkan arah evolusi menuju pengendalian emisi yang bersifat prediktif dan adaptif secara real-time. Tren validasi lintas lokasi dan penggabungan data spasial-temporal menunjukkan peningkatan perhatian terhadap generalisasi model dan penerapannya dalam skenario operasional yang

lebih luas, mendukung agenda optimalisasi berbasis data dalam sistem PLTU modern.

Kelebihan, Keterbatasan, dan Tantangan dari Pendekatan yang Digunakan

Untuk menjawab pertanyaan penelitian RQ5, yaitu "Apakah kelebihan, keterbatasan, dan tantangan dari pendekatan yang digunakan?", dilakukan analisis tematik terhadap artikel-artikel yang telah dipilih. Setiap studi dievaluasi berdasarkan cara mereka mendeskripsikan performa algoritma, skenario implementasi, serta permasalahan teknis atau praktis yang dihadapi selama proses pemodelan dan validasi.

Tabel 10. Ringkasan Kelebihan, Keterbatasan, dan Tantangan dalam Penggunaan ML untuk Prediksi Flue Gas (RQ4)

Aspek	Temuan Utama	Jurnal
Kelebihan	Memberikan akurasi yang tinggi dalam prediksi suhu, NO _x , atau efisiensi; mampu menangani data multivariat dan non-linear	[6],[7] [11], [3]
	Responsif terhadap data real-time dan cocok untuk implementasi sistem monitoring otomatis	[9], [14], [15]
Keterbatasan	Sebagian model memiliki dependensi tinggi pada kualitas dan kuantitas data; kurang efektif jika data tidak terstruktur atau tidak lengkap	[10], [17],[21]
	Tidak semua algoritma mudah diinterpretasikan (misalnya LSTM dan Transformer); hal ini menyulitkan pengambilan keputusan berbasis model	[12], [19], [30]
Tantangan	Proses tuning hiperparameter masih dilakukan secara manual atau trial-error di banyak studi	[16], [22], [31]
	Kurangnya generalisasi model terhadap kondisi operasional yang berbeda atau data dari pembangkit lain (transferability)	[13], [20], [26], [34]
	Belum banyak studi yang mengintegrasikan ML dengan aspek ekonomi atau pengambilan keputusan berbasis biaya dan efisiensi operasional jangka panjang	[18], [23], [24]

Pembahasan

Temuan dari studi ini menunjukkan bahwa penerapan *machine learning* (ML) untuk prediksi parameter flue gas, khususnya emisi NO_x, semakin mendapat perhatian dalam penelitian PLTU batubara dalam beberapa tahun terakhir. Kecenderungan ini sejalan dengan kebutuhan industri energi untuk meningkatkan efisiensi operasional sekaligus menekan emisi gas rumah kaca (IEA, 2023). Analisis terhadap RQ1 mengungkapkan bahwa sebagian besar studi berfokus pada prediksi kandungan gas emisi (35%) dan suhu flue gas (23%). Hal ini mencerminkan kesadaran yang semakin meningkat akan pentingnya pengendalian kualitas pembakaran

serta emisi berbahaya yang dihasilkan. Prediksi suhu cenderung menjadi langkah awal dalam memahami dinamika sistem pembakaran, sementara estimasi emisi NO_x lebih langsung terkait dengan kepatuhan terhadap regulasi lingkungan yang berlaku (Kementerian LHK, 2019). Dari Analisis RQ2, pendekatan seperti Random Forest, LSTM, dan XGBoost muncul sebagai algoritma yang paling banyak digunakan dan menunjukkan akurasi prediksi yang tinggi. Random Forest sering dipilih karena kemampuannya dalam menangani data non-linier dan multidimensi, sementara LSTM unggul dalam memproses data temporal dengan pola jangka panjang. Beberapa studi juga memilih GRU sebagai

alternatif yang lebih ringan dibandingkan dengan LSTM, dengan performa komputasi yang lebih cepat meskipun dengan akurasi yang sedikit berbeda (Kumar & Lee, 2023). Hal ini menunjukkan bahwa pemilihan algoritma sangat bergantung pada kompleksitas data dan kebutuhan inferensi yang spesifik. Perbandingan antara Random Forest dan SVM menunjukkan bahwa Random Forest lebih cocok digunakan pada data yang bersifat heterogen dan mengandung banyak noise, sedangkan SVM lebih unggul dalam klasifikasi presisi tinggi pada data yang lebih bersih dan terstruktur (Gupta *et al.*, 2019). Keputusan dalam pemilihan model juga dipengaruhi oleh kemudahan dalam *tuning parameter* dan interpretabilitas hasil model.

RQ3 menunjukkan bahwa parameter operasi boiler merupakan variabel input yang paling dominan, karena secara langsung memengaruhi pembentukan NOx di ruang bakar. Meskipun demikian, variabel lingkungan dan karakteristik bahan bakar juga memiliki peran penting, terutama dalam meningkatkan akurasi model dalam skenario lintas lokasi atau musim (Wang & Liu, 2020). Dalam RQ4, akurasi model menunjukkan variasi yang signifikan tergantung pada jenis algoritma yang digunakan dan parameter target yang diprediksi. Model seperti DNN dan Transformer berhasil mencapai RMSE rendah ($\leq 2^{\circ}\text{C}$) untuk suhu flue gas, sementara SVM dan model hibrida menunjukkan efisiensi dalam deteksi anomali serta peningkatan prediktabilitas NOx hingga 25% (Zhang *et al.*, 2021; Li *et al.*, 2023). Namun, sebagian besar studi masih bergantung pada dataset tunggal dari satu pembangkit dan belum banyak mengeksplorasi validasi eksternal atau penerapan model pada skala industri yang lebih besar. Studi kasus penerapan digital twin memberikan dimensi praktis dalam diskusi ini, dengan menggabungkan data sensor, simulasi sistem, dan model ML dalam satu ekosistem terpadu. Keunggulan dari pendekatan ini mencakup kemampuan prediktif secara real-time, integrasi dengan sistem SCADA/DCS, serta potensi pengembangan sistem kontrol berbasis simulasi untuk meningkatkan kinerja operasional dan efisiensi (Kusiak *et al.*, 2023). Terakhir, temuan dari RQ5 menyoroti tantangan utama dalam implementasi model. Proses *tuning parameter* yang masih dilakukan secara manual dan kurangnya generalisasi model

lintas lokasi menjadi hambatan signifikan dalam penerapan di industri. Selain itu, hanya sedikit studi yang mempertimbangkan aspek ekonomi atau biaya prediksi sebagai bagian dari evaluasi model. Implikasi penting dari temuan ini adalah adanya kebutuhan mendesak untuk penelitian interdisipliner yang menggabungkan *machine learning* dengan sistem kontrol industri, analisis data ekonomi, serta strategi adaptasi jangka panjang yang lebih berkelanjutan (Carter *et al.*, 2022; Kaleli *et al.*, 2023).

4. Kesimpulan dan Saran

Studi ini secara sistematis meninjau 31 artikel ilmiah yang membahas penggunaan *machine learning* (ML) dalam memprediksi parameter flue gas, khususnya emisi NOx pada PLTU batubara. Dari hasil analisis, mayoritas penelitian berfokus pada prediksi kandungan gas emisi dan suhu flue gas, dengan menggunakan berbagai pendekatan algoritmik seperti Random Forest, LSTM, XGBoost, serta model hibrida dan berbasis *reinforcement learning* (Kusiak *et al.*, 2023; Zhang *et al.*, 2021). Variabel input yang digunakan sangat beragam, namun sebagian besar berasal dari data operasional boiler dan karakteristik bahan bakar, yang mencerminkan keterkaitan langsung antara proses pembakaran dan emisi yang dihasilkan. Evaluasi performa model menunjukkan bahwa pendekatan *machine learning* mampu menghasilkan akurasi prediksi yang tinggi dan memiliki potensi signifikan dalam mendukung sistem monitoring serta pengendalian emisi secara real-time. Meskipun demikian, efektivitas implementasi masih menghadapi sejumlah keterbatasan. Sebagian besar studi hanya menggunakan dataset tunggal dari satu lokasi pembangkit, sehingga kemampuan generalisasi lintas lokasi belum optimal. Selain itu, ketergantungan pada data historis yang tidak selalu lengkap dan konsisten menjadi tantangan dalam pengembangan model yang lebih robust (Wang & Liu, 2020; Kumar & Lee, 2023). Proses *tuning parameter* sebagian besar masih dilakukan secara manual, dan interpretabilitas terhadap model kompleks seperti LSTM atau Transformer masih minim dalam aplikasi industri. Selain itu, sedikit studi yang mengevaluasi efektivitas model berdasarkan komponen biaya atau dampak ekonomisnya terhadap operasional PLTU (Chen *et al.*, 2023; Carter *et al.*, 2022). Berdasarkan temuan ini,

disarankan agar penelitian selanjutnya memperluas cakupan validasi terhadap data dari berbagai lokasi PLTU dan kondisi musim yang berbeda guna meningkatkan kemampuan generalisasi model. Pengembangan pendekatan *Explainable AI* (XAI) dapat menjadi langkah penting untuk memperkuat transparansi dan kepercayaan terhadap output model dalam sistem kendali industri. Selain itu, integrasi antara model prediktif dan sistem operasional seperti SCADA/DCS perlu dikaji lebih lanjut, termasuk kemungkinan penerapan kerangka pengambilan keputusan berbasis biaya. Pemanfaatan teknologi digital twin juga menunjukkan potensi besar dalam simulasi dan optimasi sistem pembakaran secara real-time (Kusiak *et al.*, 2023). Untuk menjawab kompleksitas tantangan yang ada, kolaborasi lintas disiplin antara bidang teknik, ekonomi, dan kebijakan energi dianggap krusial dalam menghasilkan solusi yang aplikatif dan berkelanjutan bagi sistem pembangkitan modern.

5. Daftar Pustaka

- Chacon-Hurtado, J. C., & Scholten, L. (2021). Decision-rama: An open-source Python library for multi-attribute value/utility decision analysis. *Environmental Modelling & Software*, 135, 104890.
- Gao, F., Wang, P., Wang, D., Yang, Y., Zhang, X., & Bai, G. (2023). Model for Predicting CO₂ Adsorption in Coal Left in Goaf Based on Backpropagation Neural Network. *Energies*, 16(9), 3760.
- Hong-Zhao, D., Hong-Mei, G., Shi-Kai, L., Fang, Y., & Qiang, Y. (2025). Synergistic effect evaluation method of atmospheric emission reduction based on deep learning fusion model. *Journal of Hazardous Materials*, 484, 136709.
<https://doi.org/10.1016/j.jhazmat.2025.11.023>.
- Jiang, W., Liu, C., & Sun, Z. (2023). Promoting developments of hydrogen production from renewable energy and hydrogen energy vehicles in China analyzing a public-private partnership cooperation scheme based on evolutionary game theory. *Energy*, 278, 127654.
<https://doi.org/10.1016/j.energy.2023.127654>
- Kaleli, A., Sungur, B., & Basar, C. (2023). Comparative study of machine learning methods integrated with different optimisation algorithms for prediction of thermal performance and emissions in a pellet stove. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 45(3), 7673-7693.
<https://doi.org/10.1080/15567036.2023.2223154>.
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering.
- Lim, C. Y., Yeo, C. E., Ahn, S. Y., & Lee, S. H. (2023). Artificial Neural Network-based Thermal Environment Prediction Model for Energy Saving of Data Center Cooling Systems. *The Journal of the Convergence on Culture Technology*, 9(6), 883-888.
- Liu, S., Hao, Y., & Ma, G. (2021). Approaches to enhance the carbonation resistance of fly ash and slag based alkali-activated mortar-experimental evaluations. *Journal of Cleaner Production*, 280, 124321.
<https://doi.org/10.1016/j.jclepro.2020.124321>
- Niu, P. K., Hong, H., & Wang, W. Z. (2020). Optimization of boiler combustion efficiency based on improved genetic algorithm. *J. Eng. Therm. Energy Power*, 35, 111-115.
- Pan, H., Su, T., Huang, X., & Wang, Z. (2021). LSTM-based soft sensor design for oxygen content of flue gas in coal-fired power plant. *Transactions of the Institute of Measurement and Control*, 43(1), 78-87.
- Pedroarena, I., Grande, L., Torrez-Herera, J. J., Korili, S. A., & Gil, A. (2023). Analysis by temperature-programmed reduction of the catalytic system Ni-Mo-Pd/Al₂O₃. *Fuel*, 334, 126789.

- Qin, J., Song, J., Tang, Y., Rui, Z., Wang, Y., & He, Y. (2023). Well applicability assessment based on fuzzy theory for CO₂ sequestration in depleted gas reservoirs. *Renewable Energy*, 206, 239-250.
<https://doi.org/10.1016/j.renene.2023.01.090>
- Ren, S., Hu, W., Bradbury, K., Harrison-Atlas, D., Valeri, L. M., Murray, B., & Malof, J. M. (2022). Automated extraction of energy systems information from remotely sensed data: A review and analysis. *Applied Energy*, 326, 119876.
<https://doi.org/10.1016/j.apenergy.2022.119876>.
- Sarkodie, B., Amesimeku, J., Frimpong, C., Howard, E. K., Feng, Q., & Xu, Z. (2023). Photocatalytic degradation of dyes by novel electrospun nanofibers: a review. *Chemosphere*, 313, 137654.
- Wahono, R. S. (2015). A systematic literature review of software defect prediction. *Journal of software engineering*, 1(1), 1-16.
- Wang, F., Wang, K., Tang, L., Li, K., & Wang, C. (2025). CO reduction in sintering flue gas by CFD-ML for process parameters optimization. *Journal of Cleaner Production*, 500, 145268.
<https://doi.org/10.1016/j.jclepro.2025.145268>.
- Xu, J., Su, Z., Meng, J., Yao, Y., Vafadaran, M. S., & Salavat, A. K. (2023). A thermodynamic, exergoeconomic, and exergoenvironmental investigation and optimization on a novel geothermal trigeneration system to sustain a sport arena. *Process Safety and Environmental Protection*, 177, 278-298.
- Yang, R., Jiang, R., Guo, S., Chen, H., Tang, S., & Duan, R. (2021). Analytical study on the Critical Water Cut for Water Plugging: Water cut increasing control and production enhancement. *Energy*, 214, 119012.
<https://doi.org/10.1016/j.energy.2020.119012>
- Zhang, W., Chen, J., Huang, G., Zu, H., Yang, Z., Qu, W., ... & Li, H. (2025). Machine Learning-Assisted Prediction and Exploration of the Homogeneous Oxidation of Mercury in Coal Combustion Flue Gas. *Environmental Science & Technology*, 59(22), 11073-11082.