

Decision Support Framework Berbasis Machine Learning untuk Strategi Perdagangan Karbon pada PLTU Batubara

Mahsun Ismail¹, R. Mohamad Atok²

^{1,2}Departemen Manajemen Teknologi, Sekolah Interdisiplin Manajemen dan Teknologi (SIMT), Institut Teknologi Sepuluh Nopember
Jl. Cokroaminoto No. 12A, Surabaya, Jawa Timur 60264
Email: mahsun.ismail@gmail.com

ABSTRAK

PLTU batubara di Indonesia ditetapkan sebagai *compliance entity* fase pertama dalam skema Nilai Ekonomi Karbon (NEK) dengan kewajiban mengelola emisi CO₂ pada mekanisme perdagangan karbon. Praktik pelaporan emisi pembangkit pada umumnya bersifat reaktif dan retrospektif, sehingga sulit menjadi dasar keputusan perdagangan karbon yang bersifat *forward-looking*. Penelitian ini mengembangkan *decision support framework* empat tahap berbasis *machine learning* yang menerjemahkan prediksi emisi tingkat pembangkit menjadi pertimbangan strategi perdagangan karbon, meliputi (1) prediksi emisi CO₂ menggunakan model *machine learning* terpilih dengan dataset 14.549 catatan operasional dari satu unit PLTU batubara 660 MW (*net*) selama tahun 2025; (2) proyeksi *Business-as-Usual* (BAU) dengan koreksi *realization rate* tiga tahun; (3) optimasi berbasis tiga skenario konservatisme (Pesimis, Moderat, Optimis); dan (4) evaluasi posisi emisi menjadi estimasi nilai transaksi dengan harga referensi IDXCarbon. Pada kondisi BAU, unit menempati posisi surplus 136.205 t-CO₂ terhadap estimasi kuota emisi sebesar 4.599.623 t-CO₂ dengan estimasi pendapatan Rp 8,01 miliar. Pada skenario Moderat, surplus meningkat menjadi 254.093 t-CO₂ dengan tambahan manfaat ekonomi Rp 6,93 miliar. Kerangka ini menempatkan analitika prediktif sebagai bahan pertimbangan pada aspek manajerial dan aspek finansial dalam perdagangan karbon.

Kata kunci: perdagangan karbon, *decision support framework*, *machine learning*, PLTU batubara, prediksi emisi CO₂

ABSTRACT

Indonesia's coal-fired power plants are designated as first-phase compliance entities under the National Carbon Economic Value (NEK) scheme, requiring them to manage CO₂ emissions within the carbon trading mechanism. Current emission accounting practices are typically reactive and retrospective, making them difficult to use as a basis for forward-looking carbon trading decisions. This study develops a four-stage machine learning-based decision support framework that translates plant-level emission predictions into considerations for carbon trading strategy: (1) CO₂ emission prediction using a selected machine learning model trained on 14,549 operational records from a 660 MW (net) coal-fired unit during 2025; (2) Business-as-Usual (BAU) projection corrected by a three-year realization rate; (3) scenario-based optimization under three conservatism levels (Pessimistic, Moderate, Optimistic); and (4) evaluate the emission positions into expected trading revenue using the IDXCarbon reference price. Under BAU, the unit holds a 136,205 t-CO₂ surplus against an estimated emission quota of 4,599,623 t-CO₂, with expected revenue of IDR 8.01 billion. Under the Moderate optimization scenario, the surplus expands to 254.093 t-CO₂ with an additional economic benefit of IDR 6.93 billion. The framework positions predictive analytics as input for managerial and financial considerations in carbon trading.

Keywords: carbon trading, *decision support framework*, *machine learning*, coal-fired power plant, CO₂ emission prediction

Pendahuluan

Perubahan iklim akibat emisi gas rumah kaca antropogenik menjadi salah satu tantangan utama keberlanjutan lingkungan global, dan sektor energi yang masih bergantung pada PLTU batubara merupakan salah satu kontributor emisi CO₂ terbesar dengan menyumbang lebih dari 30% emisi gas rumah kaca global [1]. Sebagai negara dengan bauran energi yang masih didominasi batubara, Indonesia telah meratifikasi Perjanjian Paris dan menerjemahkannya ke dalam kerangka Nilai Ekonomi Karbon (NEK) nasional [2], serta memperbarui komitmen iklimnya melalui *Second NDC* (2025) yang mengadopsi pendekatan target emisi absolut [3]. Pada subsektor ketenagalistrikan, komitmen ini diimplementasikan melalui Peraturan Menteri ESDM No. 16 Tahun 2022 yang

menetapkan *cap-and-trade* bagi PLTU batubara sebagai *compliance entity* fase pertama sejak 2023 [4]. Skema ini menciptakan kepentingan ekonomi eksplisit, yaitu setiap ton CO₂ yang direduksi menjadi sumber pendapatan potensial sedangkan setiap ton di atas alokasi menjadi liabilitas finansial. Cakupan skema NEK pada 2025 juga telah diperluas hingga mencakup PLTU *captive* dan PLTGU [5]

Pada arsitektur regulasi tersebut, *compliance entity* tidak hanya diwajibkan menginventarisasi emisi, tetapi juga mengambil keputusan strategis terkait reduksi emisi internal, penjualan unit surplus, atau pembelian alokasi tambahan. Namun, perhitungan emisi pada sebagian besar pembangkit masih bergantung pada perhitungan manual berkala yang menghasilkan data yang terlambat dan kurang granular untuk mendukung keputusan perdagangan yang bersifat *forward-looking*. Hubungan antara data operasional tingkat pembangkit dan keputusan manajerial di pasar karbon karena itu menjadi tantangan utama [6]. Walaupun fase pertama telah dijalankan, likuiditas IDXCarbon masih relatif rendah dengan rata-rata harga karbon yang terus menurun sejak peluncuran, sehingga kemampuan *compliance entity* memproyeksikan posisi perdagangan secara akurat menjadi semakin penting [7]. Pengambilan keputusan yang efektif pada konteks ini memerlukan integrasi tiga komponen yang sebelumnya terpisah, yaitu data operasional dari sistem kendali pembangkit, model analitik prediktif yang mampu menerjemahkan data tersebut menjadi proyeksi emisi, dan kerangka pengambilan keputusan yang menghubungkan proyeksi emisi dengan posisi perdagangan karbon.

Beberapa penelitian sebelumnya telah membahas prediksi emisi CO₂ dan polutan lain dari PLTU batubara menggunakan pendekatan *machine learning*. AlKheder dan Almusalam membandingkan *Artificial Neural Network* (ANN) dengan metode inventarisasi USEPA dan IPCC pada delapan PLTU di Kuwait dan menemukan ANN memberikan kinerja yang baik pada MSE dan RMSE [8]. Gu dkk. menggunakan *Extreme Gradient Boosting* (XGBoost) dan *neural network* pada data publik PLTU di New York dengan $R^2 > 0,9$ untuk NO_x, SO₂, dan CO₂ [9]. Zhu dkk. menerapkan teknik *machine learning* untuk memprediksi emisi CO₂ dari PLTU [10], sementara Herawati dkk. mengusulkan model prediktif hibrida berbasis aktivitas konsumsi bahan bakar yang sekaligus berfungsi sebagai strategi reduksi emisi [11]. Sanjeevannavar dkk. menunjukkan bahwa *gradient boosting* paling akurat ($R^2=0,99$) memprediksi efisiensi termal dan emisi CO₂ dibandingkan beberapa *machine learning* yang lain [12]. Liou dkk. [13] dan Milićević dkk. [14] selanjutnya mendemonstrasikan kapabilitas ANN dan metode *ensemble* pada data pembangkit. Studi Ashraf dkk. [15] terhadap 56 PLTU global menunjukkan bahwa optimasi berbasis *machine learning* dapat meningkatkan efisiensi energi dan menurunkan emisi karbon sepanjang umur operasi pembangkit, sementara Yin dkk. [16] mendemonstrasikan optimasi sinergis emisi CO₂ dan efisiensi termal pada PLTU 660 MW berbasis pulverized coal menggunakan *machine learning*. Penelitian terbaru oleh Liu dkk. [17] dan Setyawan dan Sudiarto [18] mengkonfirmasi bahwa model *machine learning* dapat secara bersamaan meningkatkan *heat rate* dan menurunkan intensitas emisi pada PLTU di Indonesia.

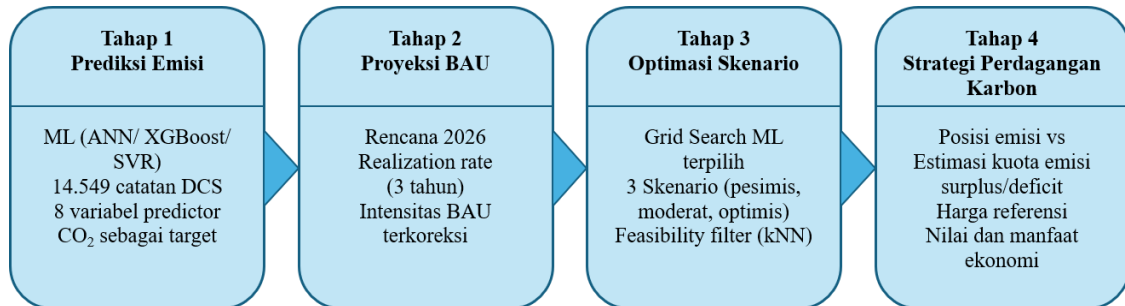
Walaupun kapabilitas teknis dari model-model tersebut sudah mapan, masih sedikit studi yang mengintegrasikan pemodelan prediktif emisi dengan realitas operasional mekanisme perdagangan karbon di Indonesia. Sebagian besar penelitian berhenti pada pelaporan akurasi model dan jarang menutup lingkaran dari prediksi ke keputusan manajerial. Zhao dkk. [19] dalam tinjauannya terhadap model prediksi emisi karbon makroskopik turut menyoroti bahwa interpretasi keluaran *machine learning* menjadi keputusan yang menghadap pasar masih belum jelas dan kurang berkembang. Selain itu, sebagian besar studi terdahulu belum mengintegrasikan koreksi statistik antara rencana dan realisasi yang merupakan titik krusial pada konteks proyeksi kuota emisi. Akibatnya, operator pembangkit menghadapi ketidakpastian dalam merancang langkah mitigasi, menilai potensi kewajiban dan peluang di pasar karbon, serta memastikan kepatuhan terhadap ketentuan regulasi. Dengan demikian, kesenjangan penelitian yang dituju studi ini bersifat spesifik, yaitu belum adanya kerangka yang secara eksplisit mengintegrasikan prediksi emisi berbasis *machine learning* tingkat pembangkit dengan penetapan posisi perdagangan karbon dalam skema *cap-and-trade* Indonesia, termasuk koreksi terhadap selisih antara rencana yang dilaporkan ke regulator dan realisasi operasi aktual.

Penelitian ini mengisi kesenjangan tersebut dengan mengembangkan decision support framework empat tahap yang mengintegrasikan model machine learning terpilih dengan alur kerja manajerial untuk perdagangan karbon. Kerangka diterapkan pada satu unit PLTU batubara 660 MW (net) yang beroperasi di Indonesia menggunakan data operasional setahun penuh yang hasilnya diterjemahkan menjadi posisi perdagangan kuantitatif beserta estimasi nilai ekonomi yang dapat diperoleh. Kontribusi penelitian ini terletak pada tiga aspek. Pertama, pengembangan kerangka pengambilan keputusan empat tahap yang menjembatani analitika prediktif dengan strategi perdagangan karbon. Kedua, perbandingan tiga algoritma *machine learning* terkemuka pada konteks data PLTU batubara di Indonesia untuk mengidentifikasi model yang paling sesuai. Ketiga, pengenalan koreksi *realization rate* sebagai mekanisme transparan untuk menjembatani konservatisme pelaporan regulasi dengan realitas operasi aktual. Ketiga aspek tersebut menyatu dalam satu kerangka terintegrasi yang menggabungkan prediksi emisi berbasis *machine learning*, proyeksi BAU terkoreksi *realization rate*, optimasi berbasis skenario, dan evaluasi nilai ekonomi sebagai dasar pengambilan keputusan manajerial dan finansial. Integrasi *end-to-end* inilah yang menjadi pembeda utama studi ini dari penelitian prediksi emisi terdahulu yang sebagian besar berhenti pada pelaporan akurasi model tanpa menautkannya dengan keputusan perdagangan karbon.

Metode Penelitian

Desain Penelitian

Penelitian ini menggunakan desain studi kasus terapan pada satu unit PLTU batubara berkapasitas 660 MW (*net*) yang beroperasi di Indonesia. Unit tersebut merupakan salah satu *compliance entity* fase pertama dalam skema NEK. *Decision support framework* empat tahap dikembangkan seperti ditunjukkan pada **Gambar 1** terdiri atas (1) prediksi emisi, (2) proyeksi BAU dengan koreksi *realization rate*, (3) optimasi berbasis skenario, dan (4) strategi perdagangan karbon. Setiap tahap menghasilkan keluaran yang menjadi masukan tahap berikutnya, membentuk alur kerja dari data sensor hingga pertimbangan keputusan manajerial. Pendekatan ini menempatkan *machine learning* bukan sebagai produk akhir, melainkan sebagai satu blok analitis dalam alur kerja yang lebih luas yang mengaitkan data operasional, proyeksi regulasi, dan evaluasi ekonomi pasar karbon.



Gambar 1. Diagram alur *decision support framework*

Sumber Data

Data operasional diekstraksi dari *Distributed Control System* (DCS) pembangkit untuk periode 1 Januari 2025 hingga 31 Desember 2025 pada interval 30 menit. Seluruh variabel input diperoleh dari instrumen lapangan yang terintegrasi dengan DCS dan dipelihara sesuai prosedur operasi pembangkit sehingga keandalan pengukurannya terjaga, validitas nilai data selanjutnya dipastikan melalui tahapan *pre-processing*. Tahapan *pre-processing* yang dilakukan meliputi penyaringan kondisi *steady-state* pada daya di atas 400 MW untuk mengeluarkan periode *start-up* dan *shutdown*, *winsorization outlier* menggunakan metode *interquartile range* (IQR), dan penyaringan intensitas CO₂ pada rentang persentil 2 hingga 98 untuk membuang kondisi operasi yang tidak representatif. Variabel yang dipantau meliputi *coal flow rate*, *stack temperature*, *excess oxygen* pada boiler, *furnace exit gas temperature*, *gross efficiency*, tekanan gas buang, vakum kondensor, dan temperatur uap utama. Beban emisi CO₂ diakuisisi secara paralel dari *Continuous Emission Monitoring System* (CEMS), yang merupakan instrumen pengukuran emisi langsung pada cerobong dengan standar Tier 4 IPCC sehingga memberikan dasar empiris yang akurat untuk pelatihan model prediksi.

Data tambahan terkait rencana produksi 2026, target intensitas emisi yang dilaporkan ke Kementerian ESDM, estimasi alokasi kuota emisi, dan harga referensi diperoleh dari IDXCarbon. Sebelum digunakan dalam pemodelan, dilakukan seleksi fitur dua tahap. Tahap pertama berupa *screening* korelasi Pearson untuk mengidentifikasi pola hubungan linier antara variabel prediktor dan variabel target. Tahap kedua berupa eliminasi iteratif berdasarkan *Variance Inflation Factor* (VIF) dengan ambang batas VIF < 10 untuk menghindari multikolinearitas yang berlebihan, yang dapat menyebabkan instabilitas pada model *distance-based* dan *gradient-based* serta menurunkan kapabilitas generalisasi.

Prediksi Emisi

Model prediktif untuk beban emisi CO₂ dikembangkan menggunakan *machine learning*. Variabel prediktor yang digunakan sebagai input model merupakan variabel yang lolos seleksi fitur Pearson dan VIF, sedangkan beban emisi CO₂ yang diukur dari CEMS digunakan sebagai variabel target. Tiga algoritma kandidat dievaluasi dan dibandingkan, yaitu *Artificial Neural Network*, *Extreme Gradient Boosting*, dan *Support Vector Regression*. Pemilihan tiga algoritma ini didasarkan pada literatur prediksi emisi yang menunjukkan ketiganya sebagai pendekatan yang paling banyak digunakan dan menghasilkan kinerja kompetitif pada berbagai konteks pembangkitan listrik.

Dataset dibagi menjadi 80% set pelatihan dan 20% set pengujian secara kronologis untuk menjaga karakteristik *time-series* data operasional. Optimasi hyperparameter dilakukan dengan *Randomized Search Cross-Validation* menggunakan *TimeSeriesSplit* tiga *fold* untuk menjaga konsistensi urutan waktu data dan menghindari

data leakage. Evaluasi komparatif menggunakan tiga metrik standar regresi yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2) untuk menilai akurasi dan kemampuan generalisasi setiap model. Model dengan kinerja terbaik dipilih sebagai model yang akan digunakan pada tahap-tahap selanjutnya dalam kerangka pengambilan keputusan.

Proyeksi BAU dengan Koreksi Realization Rate

Compliance entity wajib melaporkan rencana produksi dan target emisi tahunan ke Kementerian ESDM melalui sistem APPLE-Gatrik sesuai amanat Permen ESDM No. 16 Tahun 2022. Rencana yang dilaporkan umumnya menggunakan faktor emisi *default* sehingga cenderung konservatif terhadap operasi yang sebenarnya. Untuk memperoleh proyeksi BAU yang lebih representatif, penelitian ini menerapkan koreksi *realization rate* yang didefinisikan sebagai rasio antara intensitas emisi realisasi terhadap intensitas rencana yang dilaporkan, dihitung pada tiga tahun terakhir historis pembangkit. *Realization rate* (RR) dihitung sebagai $RR = (1/n) \times \sum (IR_t / IP_t)$ untuk $t = 1..n$ tahun, dengan IR_t dan IP_t berturut-turut adalah intensitas emisi realisasi dan intensitas rencana pada tahun ke- t , serta $n = 3$. Nilai $RR < 1$ menunjukkan realisasi yang konsisten lebih rendah daripada rencana sebagai bentuk konservatisme pelaporan, sehingga intensitas BAU terkoreksi diperoleh dengan mengalikan intensitas rencana tahun proyeksi dengan RR rata-rata tiga tahun. *Realization rate* rata-rata tiga tahun tersebut kemudian diterapkan pada intensitas rencana untuk tahun proyeksi guna memperoleh intensitas BAU terkoreksi, yang kemudian dikalikan dengan rencana produksi bruto untuk menghasilkan estimasi total emisi BAU.

Pendekatan ini memiliki dua keunggulan. Pertama, koreksi *realization rate* memanfaatkan data historis aktual pembangkit sehingga tidak bergantung pada asumsi eksternal yang sulit divalidasi. Kedua, perhitungan rasio *rolling* tiga tahun memberikan keseimbangan antara representativitas data terkini dan stabilitas statistik karena variasi tahunan tertentu yang ekstrem akan terdistribusi rata-rata pada rentang tersebut. Proyeksi BAU yang dihasilkan kemudian menjadi titik referensi untuk menilai posisi awal pembangkit terhadap kuota emisi sebelum penerapan langkah optimasi.

Optimasi Berbasis Skenario

Optimasi operasional dilakukan pada parameter operasional yang teridentifikasi sebagai faktor dominan yang mempengaruhi intensitas emisi CO₂ berdasarkan *feature importance*. Parameter yang dipertimbangkan untuk dioptimasi adalah parameter yang memenuhi dua karakteristik secara bersamaan, yaitu memiliki kontribusi signifikan terhadap variasi emisi sesuai analisis *feature importance* dan dapat dikendalikan oleh operator dalam operasi normal pembangkit. Parameter yang merupakan respons terhadap permintaan beban eksternal tidak diperlakukan sebagai parameter yang dapat dikendalikan secara independen oleh pembangkit, walaupun memiliki *feature importance* yang tinggi.

Optimasi dilakukan dengan *grid search* pada parameter terpilih dengan 100 grid points per parameter, menghasilkan 10.000 kombinasi yang dievaluasi pada masing-masing rentang beban. Filter kelayakan kNN ($k = 5$) diterapkan dengan ambang batas feasibility 0,20 secara konsisten pada ketiga skenario. Model XGBoost berfungsi sebagai evaluator fungsi tujuan untuk memprediksi intensitas CO₂ pada setiap kombinasi parameter. Untuk memastikan rekomendasi yang dihasilkan tetap realistis dan dapat diimplementasikan, pencarian dibatasi oleh *feasibility filter* yang diimplementasikan dengan *k-nearest neighbors* (kNN, $k = 5$) pada ruang parameter terstandarisasi. Hanya kombinasi parameter yang memiliki kedekatan dengan distribusi historis aktual pembangkit yang dipertahankan sebagai kandidat optimum.

Tiga skenario rentang pencarian didefinisikan untuk mengakomodasi tingkat preferensi risiko manajerial yang berbeda, yaitu Pesimis (P20-P80) yang membatasi pencarian pada 60% bagian tengah distribusi historis; Moderat (P10-P90) atau 80% bagian tengah; dan Optimis (P5-P95) atau 90% bagian tengah. Skenario Moderat digunakan sebagai acuan utama dalam pembahasan karena memberikan keseimbangan antara potensi reduksi dan risiko implementasi. Skenario Pesimis dan Optimis berfungsi sebagai batas bawah dan batas atas estimasi untuk perencanaan berbasis rentang (*range planning*) dalam menghadapi ketidakpastian pasar dan operasi.

Strategi Perdagangan Karbon

Proyeksi BAU terkoreksi dan setiap skenario optimasi menghasilkan estimasi total emisi tahunan yang dibandingkan dengan estimasi alokasi kuota emisi. Apabila emisi aktual berada di bawah *cap*, entitas berada pada posisi surplus dan dapat menjual unit surplus. Apabila emisi melebihi *cap*, entitas harus membeli unit atau *offset* karbon untuk memenuhi kepatuhan. Nilai ekonomi dari setiap posisi dihitung dengan mengalikan volume surplus atau defisit dengan harga referensi IDXCarbon sebesar Rp 58.800 per ton CO₂ sesuai catatan transaksi Desember 2025. Tambahan manfaat ekonomi dari optimasi kemudian dihitung sebagai selisih antara pendapatan perdagangan pada skenario optimasi dengan pendapatan perdagangan pada kondisi BAU. Pendekatan ini

menghasilkan ukuran kuantitatif yang dapat dibandingkan dengan biaya implementasi optimasi maupun opsi investasi lain dalam portofolio dekarbonisasi pembangkit.

Hasil Dan Pembahasan

Karakteristik Dataset Hasil Pre-Processing dan Seleksi Fitur

Tahapan *pre-processing* menghasilkan dataset akhir 14.549 catatan per jam pada 2025. Pengurangan jumlah catatan dari data mentah disebabkan oleh tiga tahapan filtrasi, yaitu penyaringan kondisi *steady-state* pada daya di atas 400 MW yang membuang periode *start-up* dan *shutdown*, *winsorization outlier* menggunakan metode *interquartile range*, dan penyaringan intensitas emisi pada rentang persentil 2 hingga 98. Dataset hasil *pre-processing* ini mencerminkan operasi pembangkit pada kondisi normal yang menjadi basis pelatihan model prediksi. Seleksi fitur melalui *screening* korelasi Pearson dan eliminasi iteratif VIF menghasilkan delapan variabel prediktor yang independen dan informatif. Variabel-variabel tersebut adalah *coal flow rate*, *excess oxygen* pada boiler, *furnace exit gas temperature*, vakum kondensor, *gross efficiency*, tekanan gas buang, *stack temperature*, dan temperatur uap utama. Variabel-variabel yang memiliki korelasi tinggi dengan variabel lain dan ber-VIF di atas ambang batas dieliminasi secara iteratif. Beban emisi CO₂ yang diukur dari CEMS sebagai variabel target.

Perbandingan Kinerja Model machine learning

Evaluasi komparatif algoritma *machine learning* dilakukan untuk memilih model untuk dipakai dalam kerangka pengambilan keputusan. **Tabel 1** merangkum metrik kinerja ketiga model pada set pengujian.

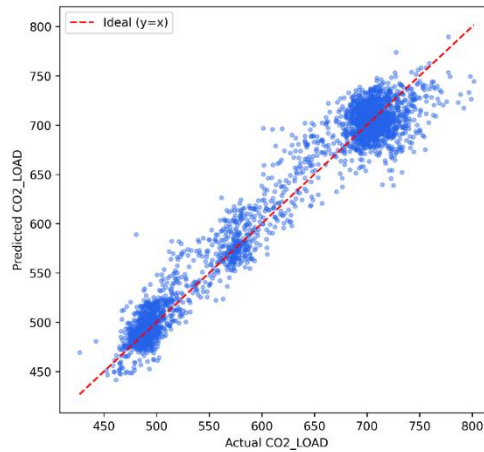
Tabel 1. Perbandingan kinerja model *machine learning* pada prediksi emisi CO₂

Model	MAE Pengujian		RMSE Pengujian		R ² Pengujian	R ² Pelatihan
	(t-CO ₂ /jam)	(%)	(t-CO ₂ /jam)	(%)		
ANN	22,09	3,57	25,55	4,13	0,932	0,963
XGBoost	15,84	2,56	20,53	3,32	0,956	0,968
SVR	23,39	3,78	29,96	4,84	0,907	0,931

Berdasarkan perbandingan pada **Tabel 1**, XGBoost menunjukkan performa generalisasi terbaik dengan MAE pengujian 15,84 t-CO₂/jam (2,56%), RMSE pengujian 20,53 t-CO₂/jam (3,32%), dan R² pengujian 0,956, lebih unggul dari SVR (R² pengujian 0,907) dan ANN (R² pengujian 0,932). Selisih R² pelatihan dan pengujian yang sangat kecil pada XGBoost (0,968 vs 0,956) mengindikasikan tidak terjadi *overfitting* pada model. Jika dibandingkan dengan literatur internasional, akurasi model prediksi pada studi ini tergolong kompetitif, terutama bila ditinjau dari koefisien determinasi (R²) yang tidak bergantung pada skala. Gu dkk. [9] memprediksi laju emisi dengan XGBoost dengan R² pada kisaran 0,95-0,96, setara dengan R² 0,956 pada studi ini. Liu dkk. [17] memodelkan emisi karbon PLTU memperoleh R² 0,9514 juga sebanding dengan capaian studi ini. Yin dkk. [16] memodelkan intensitas emisi karbon PLTU dengan *Gaussian Process Regression* dan melaporkan R² 0,895 sebelum melakukan optimasi multi-objektif, sedikit lebih rendah dari studi ini. Dengan demikian, model prediksi emisi pada studi ini berada pada tingkat akurasi yang setara atau lebih baik dibandingkan rujukan-rujukan tersebut, sekaligus memperluasnya hingga penerjemahan hasil prediksi menjadi keputusan perdagangan karbon.

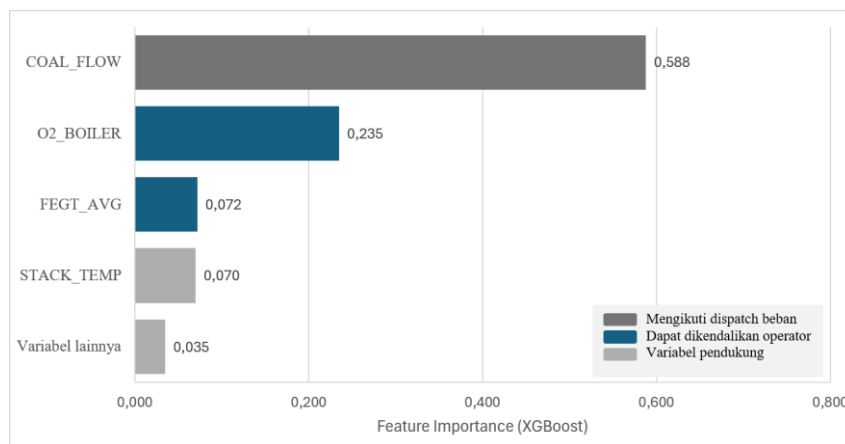
Keunggulan XGBoost ini konsisten dengan temuan Sanjeevannavar dkk. [12] yang juga menunjukkan keunggulan *gradient boosting* pada prediksi emisi. Kemampuan XGBoost menangkap interaksi non-linear antar parameter operasional melalui mekanisme *boosting* iteratif menjadikan model ini sebagai pilihan yang digunakan pada tahap selanjutnya. Pada konteks data operasional pembangkit yang bersifat deret waktu dan tabular, keunggulan XGBoost juga ditopang oleh ketahanannya terhadap pencilan dan derau sensor serta kemampuannya menangkap interaksi antarparameter operasi tanpa memerlukan asumsi distribusi tertentu. Karakteristik ini membuatnya lebih stabil dibandingkan ANN yang lebih sensitif terhadap pengaturan dan ukuran data, maupun SVR yang kurang fleksibel terhadap interaksi fitur yang kompleks. Pendekatan ini sejalan dengan praktik yang berkembang di literatur di sub sektor pembangkit listrik dimana kombinasi XGBoost dengan *feature importance* banyak digunakan mengidentifikasi parameter dominan sebagai titik intervensi optimasi [20].

Sebaran titik prediksi terhadap aktual yang ditunjukkan pada **Gambar 2** terlihat mengelompok rapat di sekitar garis ideal $y=x$ pada seluruh rentang nilai CO₂_LOAD dari sekitar 430 hingga 800 t-CO₂/jam. Konsentrasi titik terlihat pada kluster beban rendah sekitar 450-50 t-CO₂/jam, beban menengah di sekitar 550-650 t-CO₂/jam, dan beban tinggi sekitar 650-750 t-CO₂/jam yang memiliki sebaran data paling padat, yang merefleksikan distribusi historis operasi unit. Tidak terdapat *bias* sistematis pada salah satu rentang, dan deviasi terbesar tetap berada dalam batas yang konsisten dengan RMSE pengujian 20,53 t-CO₂/jam (3,32%), mengonfirmasi bahwa akurasi model tidak terdegradasi pada salah satu zona operasi tertentu.



Gambar 2. Actual vs Predicted CO₂_LOAD pada set pengujian (XGBoost, R² = 0,956)

Analisis *feature importance* pada model XGBoost mengidentifikasi empat parameter operasional dominan yang berkontribusi signifikan terhadap variasi emisi CO₂, sebagaimana disajikan pada **Gambar 3**. Variabel *coal flow rate* pada **Gambar 3** menempati urutan pertama dengan *feature importance* 0,588, yang mencerminkan hubungan stoikiometris langsung antara konsumsi bahan bakar dan produksi CO₂. Posisi berikutnya ditempati O₂_BOILER (0,235), FEGT_AVG (0,072), dan STACK_TEMP (0,070). Dua parameter sisi pembakaran yang dapat dikendalikan operator, yaitu O₂_BOILER dan FEGT_AVG, menjadi fokus pada tahap optimasi; sedangkan COAL_FLOW yang merupakan parameter yang mengikuti dispatch beban pembangkit, dan STACK_TEMP yang merupakan indikator komposit setelah *air preheater*, ESP, dan FGD dikesualikan.



Gambar 3. Feature importance parameter operasional pada model XGBoost

Proyeksi Emisi pada Kondisi Business-as-Usual

Rencana produksi bruto pembangkit untuk tahun 2026 yang dilaporkan adalah 4.895.769,07 MWh dengan target emisi 4.755.212,80 t-CO₂ dengan intensitas rencana 0,971 t-CO₂/MWh. Untuk memperoleh proyeksi BAU yang lebih representatif terhadap operasi aktual, dilakukan koreksi kecenderungan antara intensitas rencana dan intensitas realisasi historis dengan data *realization rate* tiga tahun terakhir diringkaskan pada **Tabel 2**.

Tabel 2. Realization rate intensitas emisi

Tahun	Intensitas Rencana (t-CO ₂ /MWh)	Intensitas Realisasi (t-CO ₂ /MWh)	Realization Rate
2023	0,946	0,888	0,939
2024	0,938	0,888	0,947
2025	0,950	0,884	0,931
Rata-rata	0,945	0,887	0,939

Berdasarkan **Tabel 2**, rata-rata *realization rate* tiga tahun sebesar 0,939 menunjukkan bahwa intensitas realisasi secara konsisten berada sekitar 6,1% di bawah intensitas rencana, mencerminkan konservatisme

sistematis dalam pelaporan regulasi dibandingkan operasi aktual. Penerapan *realization rate* tersebut pada intensitas rencana 2026 menghasilkan intensitas BAU terkoreksi sebesar 0,912 t-CO₂/MWh, setara dengan proyeksi total emisi BAU 4.463.418,09 t-CO₂ terhadap rencana produksi 4.895.769,07 MWh.

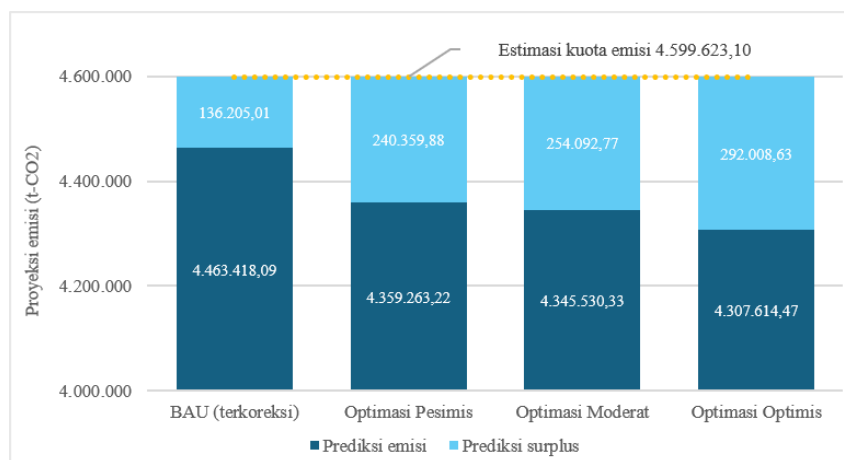
Optimasi menghasilkan rata-rata tertimbang reduksi sebesar 2,33%-3,49% relatif terhadap BAU, setara dengan reduksi absolut antara 104.154,87 t-CO₂ hingga 155.803,62 t-CO₂ yang ditunjukkan pada **Tabel 3**. Rentang reduksi ini mencerminkan derajat agresivitas pencarian titik optimum. Skenario Pesimis hanya mengeksplorasi rentang persentil 20-80 dari distribusi historis sehingga menghasilkan reduksi paling konservatif, sementara skenario Optimis memperluas rentang ke persentil 10-90 yang mencakup titik operasi yang lebih jarang dijumpai namun tetap pernah terealisasi. Pada skenario Moderat yang dijadikan acuan utama, proyeksi reduksi sebesar 117.887,76 t-CO₂ atau 2,64% dari BAU. Reduksi ini dapat diperoleh melalui pengaturan operasional dalam rentang historis operasi pembangkit, tanpa investasi peralatan baru, tanpa perubahan bahan bakar, dan tanpa modifikasi beban yang berikan oleh *dispatcher*.

Tabel 3. Estimasi emisi CO₂ tahun 2026 pada kondisi BAU dan skenario optimasi

Skenario	Produksi Bruto (MWh)	Intensitas (t-CO ₂ /MWh)	Emisi (t-CO ₂)	Reduksi vs BAU
Rencana dilaporkan	4.895.769,07	0,971	4.755.212,80	-
BAU (terkoreksi)	4.895.769,07	0,912	4.463.418,09	-
Optimasi - Pesimis	4.895.769,07	0,890	4.359.263,22	2,33%
Optimasi - Moderat	4.895.769,07	0,888	4.345.530,33	2,64%
Optimasi - Optimis	4.895.769,07	0,880	4.307.614,47	3,49%

Posisi Terhadap Estimasi Cap

Pada saat penelitian ini dilakukan, alokasi kuota emisi resmi untuk unit tersebut belum diterbitkan oleh Kementerian ESDM, estimasi kuota emisi sebesar 4.599.623,10 t-CO₂ digunakan untuk mengevaluasi posisi perdagangan. Angka estimasi ini diperoleh dari pendekatan perhitungan berdasarkan data historis intensitas emisi dan juga total emisi yang dihasilkan sesuai metodologi yang diatur dalam Permen ESDM No. 16 Tahun 2022. Apabila alokasi resmi nantinya diterbitkan dengan nilai yang berbeda, posisi surplus/defisit akan bergeser secara proporsional, namun struktur perbandingan antar skenario tidak berubah.



Gambar 4. Posisi proyeksi emisi terhadap estimasi kuota emisi cap 2026 pada empat skenario

Gambar 4 membandingkan proyeksi emisi terhadap estimasi *cap* pada setiap skenario. Pada kondisi BAU, unit diproyeksikan sebagai *net seller* dengan surplus 136.205,01 t-CO₂ terhadap estimasi *cap*, bahkan tanpa intervensi. Artinya unit pembangkit objek studi sudah memiliki posisi perdagangan yang menguntungkan tanpa melakukan langkah optimasi tambahan, yang menunjukkan kinerja emisi yang relatif baik dibandingkan tolok ukur sektor. Selain itu, estimasi surplus telah ada sejak BAU juga menyiratkan metodologi alokasi kuota emisi sektor masih lebih longgar dibanding intensitas emisi di unit pembangkit ini. Optimasi ini memperluas surplus menjadi 240.359,88 t-CO₂ (Pesimis), 254.092,77 t-CO₂ (Moderat), dan 292.008,63 t-CO₂ pada skenario Optimis.

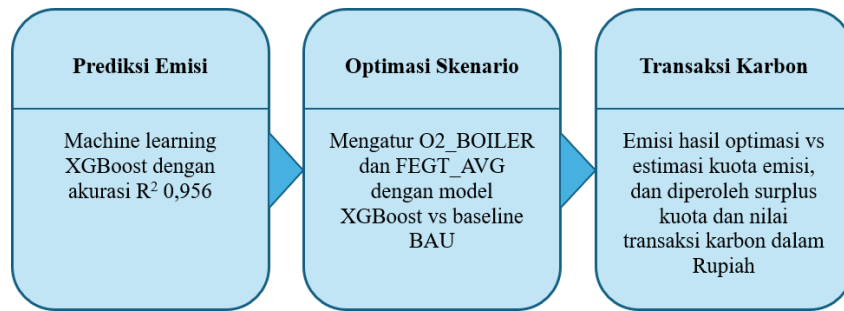
Strategi Perdagangan Karbon dan Nilai Ekonomi

Karena unit menempati posisi surplus pada seluruh skenario, strategi perdagangan yang sesuai adalah menjual unit surplus. Menggunakan harga referensi IDXCcarbon Rp 58.800 per ton CO₂, proyeksi pendapatan perdagangan dan tambahan manfaat ekonomi yang dapat diatribusikan pada optimasi diringkaskan pada **Tabel 4**.

Tabel 4. Estimasi nilai transaksi perdagangan karbon pada setiap skenario (2026)

Komponen	BAU	Pesimis	Moderat	Optimis
Volume surplus (t-CO ₂)	136.205,01	240.359,88	254.092,77	292.008,63
Harga referensi (Rp/t-CO ₂)	58.800	58.800	58.800	58.800
Strategi	Jual	Jual	Jual	Jual
Pendapatan transaksi (Rp miliar)	8,01	14,13	14,94	17,17
Tambahan manfaat vs BAU (Rp miliar)	-	6,12	6,93	9,16

Pada **Tabel 4**, kondisi BAU unit dapat menghasilkan estimasi pendapatan Rp 8,01 miliar semata-mata dari penjualan posisi surplus yang sudah ada. Penerapan rekomendasi optimasi menaikkan pendapatan transaksi menjadi Rp 14,13 miliar hingga Rp 17,17 miliar tergantung skenario yang diterapkan, atau Rp 14,94 miliar pada skenario Moderat sebagai acuan. Tambahan manfaat ekonomi yang dapat diatribusikan secara langsung pada optimasi berkisar antara Rp 6,12 miliar hingga Rp 9,16 miliar, dengan Rp 6,93 miliar sebagai nilai konservatif. Rentang Pesimis hingga Optimis menyampaikan informasi terkait sensitivitas hasil ekonomi terhadap preferensi risiko manajerial. Lebar antara estimasi Pesimis dan Optimis sekitar Rp 3 miliar menggambarkan seberapa besar nilai ekonomi yang dipertaruhkan dalam pilihan tingkat konservatisme. Ketiga skenario itu dapat dimaknai sebagai representasi profil pengambil keputusan: skenario Pesimis selaras dengan manajemen yang bersikap konservatif (risk-averse) dan memprioritaskan kepastian pemenuhan kuota emisi; skenario Optimis mencerminkan preferensi yang lebih agresif terhadap potensi manfaat ekonomi; sedangkan skenario Moderat menyeimbangkan keduanya. Dengan demikian, keluaran kerangka tidak bersifat preskriptif tunggal, melainkan menyediakan rentang opsi yang dapat dipilih manajemen sesuai selera risiko dan kebijakan perusahaan. Dengan kerangka berbasis skenario ini, *compliance entity* memiliki pemahaman terkait batas bawah dan batas atas potensi perbaikan, bukan sekadar mengandalkan satu titik proyeksi tunggal.



Gambar 5. Alur integrasi prediksi emisi, optimasi skenario, dan transaksi perdagangan karbon

Integrasi tiga tahap inti *Decision Support Framework* dari prediksi emisi hingga keputusan transaksi karbon diringkas pada **Gambar 5**. Prediksi intensitas emisi CO₂ oleh model machine learning (XGBoost) dengan R² 0,956 menjadi masukan bagi tahap optimasi berbasis skenario yang mengatur parameter operasi terkendali berupa O₂_BOILER dan FEGT_AVG untuk menurunkan intensitas emisi dibandingkan dengan baseline BAU terkoreksi *realization rate*. Pada skenario Moderat, optimasi menghasilkan reduksi 117.888 t-CO₂ (2,64%). Posisi emisi hasil optimasi kemudian dibandingkan terhadap estimasi alokasi kuota emisi sebesar 4.599.623 t-CO₂ yang menentukan besaran potensi surplus sebesar 254.093 t-CO₂ pada skenario Moderat yang diterjemahkan menjadi keputusan transaksi karbon beserta nilai ekonominya, yaitu pendapatan Rp 14,94 miliar dengan tambahan manfaat Rp 6,93 miliar. Dengan demikian, **Gambar 5** memperlihatkan bagaimana keluaran prediktif model secara berurutan diubah menjadi keputusan operasional dan finansial bagi manajemen pembangkit.

Implikasi Manajerial

Kerangka ini memberikan implikasi pada dua kelompok pengambil keputusan yang berbeda di dalam *compliance entity*. Bagi manajemen pembangkit, hasil penelitian memberikan dasar empiris untuk justifikasi investasi dalam pemantauan operasional dan analitika lanjutan. Reduksi intensitas emisi sebesar 2,64% yang dicapai tanpa belanja modal merupakan hal yang tidak lazim di sektor ketenagalistrikan, dimana sebagian besar jalur dekarbonisasi memerlukan *co-firing*, *retrofit*, atau penggantian bahan bakar. Kerangka ini merekomendasikan pengaturan O₂_BOILER dan FEGT_AVG (dua parameter sisi pembakaran yang dapat dikendalikan) menuju *set-point* yang telah diobservasi pada sejarah operasi pembangkit, semua dalam batas praktik operasi normal. Karena rekomendasi titik operasi optimum berasal dari data historis aktual unit, risiko implementasi relatif rendah dibandingkan rekomendasi berbasis asumsi atau hasil simulasi teoretis.

Pada aspek finansial, kerangka ini mendukung perencanaan transaksi unit karbon. Pengetahuan tentang volume surplus yang diproyeksikan dan sensitivitas berbasis skenario memungkinkan manajemen keuangan merencanakan waktu dan volume penjualan. Kerangka ini juga membantu manajemen keuangan membedakan antara pendapatan yang berasal dari praktik operasi yang sudah ada (surplus BAU senilai Rp 8,01 miliar) dengan pendapatan yang membutuhkan perubahan operasional eksplisit (tambahan Rp 6,93 miliar pada skenario Moderat). Perbedaan ini mendukung atribusi yang lebih jelas dalam pelaporan kinerja internal dan menjadi landasan untuk negosiasi insentif kinerja antara fungsi operasi dan fungsi keuangan.

Secara keseluruhan, kerangka ini memposisikan analitika prediktif sebagai komponen yang terintegrasi dengan proses pengambilan keputusan, bukan sebagai produk teknis yang berdiri sendiri. Integrasi dua aspek, yaitu aspek operasional dan aspek finansial, pada satu kerangka memberikan gambaran yang lebih utuh tentang dampak keputusan optimasi pada rantai nilai pembangkit.

Keterbatasan dan Penelitian Lanjutan

Penelitian ini memiliki sejumlah keterbatasan yang perlu diperhatikan dalam menafsirkan hasilnya. Pertama, studi difokuskan pada satu unit PLTU batubara 660 MW (net), sehingga generalisasi hasil ke unit dengan karakteristik teknologi, bahan bakar, atau pola dispatch yang berbeda, maupun ke sistem jaringan yang berbeda, masih perlu diverifikasi lebih lanjut. Kedua, proyeksi BAU mengasumsikan stabilitas *realization rate* berdasarkan rata-rata tiga tahun, padahal rasio ini dapat bergeser akibat perubahan kondisi teknis pembangkit maupun kebijakan pelaporan. Ketiga, estimasi nilai ekonomi menggunakan harga referensi IDXCarbon pada satu titik waktu dan belum memodelkan fluktuasi harga karbon jangka panjang serta ketidakpastian likuiditas pasar. Keempat, estimasi kuota emisi digunakan sebagai pengganti alokasi resmi yang belum diterbitkan, sehingga besaran surplus absolut bersifat indikatif. Penelitian lanjutan disarankan untuk memperluas cakupan ke beberapa unit atau portofolio pembangkit, menerapkan pemodelan *realization rate* yang dinamis, serta mengintegrasikan skenario harga karbon stokastik guna memperkuat analisis sensitivitas finansial.

Simpulan

Penelitian ini mengusulkan dan mendemonstrasikan *decision support framework* empat tahap berbasis *machine learning* yang mengkonversi data operasional tingkat pembangkit menjadi bahan pertimbangan keputusan perdagangan karbon bagi compliance entity di sektor ketenagalistrikan Indonesia. Diterapkan pada satu unit PLTU batubara 660 MW (net), kerangka tersebut memproyeksikan surplus BAU sebesar 136.205 t-CO₂ terhadap estimasi kuota emisi 4.599.623 t-CO₂, menghasilkan pendapatan Rp 8,01 miliar. Pada skenario Moderat optimasi, surplus meluas menjadi 254.093 t-CO₂ dan pendapatan perdagangan meningkat menjadi Rp 14,94 miliar, menghasilkan tambahan manfaat ekonomi Rp 6,93 miliar yang dapat diatribusikan pada pengaturan operasional. Dari ketiga model yang dievaluasi, XGBoost memberikan performa prediksi terbaik dengan MAE pengujian 15,84 t-CO₂/jam (2,56%); RMSE pengujian 20,53 t-CO₂/jam (3,32%); dan R² pengujian 0,956, lebih unggul dibandingkan SVR (R² pengujian 0,907) dan ANN (R² pengujian 0,932). Faktor operasional dominan yang teridentifikasi adalah coal flow rate (COAL_FLOW), *excess oxygen* pada boiler (O2_BOILER), furnace exit gas temperature (FEGT_AVG), dan stack temperature (STACK_TEMP) dengan dua parameter yang dapat dikendalikan oleh operator yaitu O2_BOILER dan FEGT_AVG menjadi titik intervensi pada tahap optimasi. Kerangka ini berfungsi sebagai bahan pertimbangan pada aspek manajerial dan aspek finansial, bukan sebagai pengambil keputusan otomatis.

Daftar Pustaka

- [1] A. Mishra, N. Das, and P. Chhetri, "Sustainable Strategies for the Indian Coal Sector: An Econometric Analysis Approach," *Sustainability (Switzerland)*, vol. 15, no. 14, Jul. 2023, doi: 10.3390/su151411129.
- [2] N. Dzahabiyah, M. Priyanta, and Y. Adharani, "Arah pengaturan terkait pembangunan PLTU di Indonesia sebagai bentuk komitmen terhadap Paris climate agreement," *LITRA: Jurnal Hukum Lingkungan, Tata Ruang, dan Agraria*, vol. 1, no. 2, pp. 185–204, Apr. 2022, doi: 10.23920/litra.v1i2.725.
- [3] Government of Indonesia, "Second Nationally Determined Contribution Republic of Indonesia," 2025.
- [4] Kementerian Energi dan Sumber Daya Mineral Republik Indonesia, "Peraturan Menteri Energi dan Sumber Daya Mineral Republik Indonesia Nomor 16 Tahun 2022 tentang tata cara penyelenggaraan nilai ekonomi karbon pada sub sektor pembangkitan tenaga listrik," 2022. [Online]. Available: www.peraturan.go.id

- [5] International Carbon Action Partnership, "Emission Trading Worldwide: Status Report 2025," 2025.
- [6] V. Kumar, "The Physics Behind Climate Change: Understanding Greenhouse Gases," *International Journal of Innovations in Science Engineering And Management*, pp. 21–25, Oct. 2024, doi: 10.69968/ijsem.2024v3i421-25.
- [7] N. McCulloch, F. Joy, J. Cordon-Navarro, M. Duong, and S. Dünnenberger, "Implementing Carbon Pricing in Southeast Asia," 2026.
- [8] S. AlKheder and A. Almusalam, "Forecasting of carbon dioxide emissions from power plants in Kuwait using United States Environmental Protection Agency, Intergovernmental panel on climate change, and machine learning methods," *Renew. Energy*, vol. 191, pp. 819–827, May 2022, doi: 10.1016/j.renene.2022.04.023.
- [9] J. Gu, J. A. Sward, and K. M. Zhang, "Predicting power plant emissions using public data and machine learning," *Environmental Science: Advances*, vol. 2, no. 12, pp. 1696–1707, Oct. 2023, doi: 10.1039/d3va00191a.
- [10] C. Zhu, P. Shi, Z. Li, M. Li, H. Zhang, and T. Ding, "Carbon Emission Prediction of Thermal Power Plants Based on Machine Learning Techniques," in *2022 5th International Conference on Energy, Electrical and Power Engineering, CEEPE 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1142–1146. doi: 10.1109/CEEPE55110.2022.9783417.
- [11] N. A. Herawati, A. A. P. Gary, E. Hikmawati, and K. Surendro, "A Hybrid Predictive Model as an Emission Reduction Strategy Based on Power Plants' Fuel Consumption Activity," *IEEE Access*, vol. 12, pp. 47119–47133, 2024, doi: 10.1109/ACCESS.2024.3380809.
- [12] M. B. Sanjeevannavar *et al.*, "Machine Learning Prediction and Optimization of Performance and Emissions Characteristics of IC Engine," *Sustainability (Switzerland)*, vol. 15, no. 18, Sep. 2023, doi: 10.3390/su151813825.
- [13] J. L. Liou, K. C. Liao, H. T. Wen, and H. Y. Wu, "A study on nitrogen oxide emission prediction in Taichung thermal power plant using artificial intelligence (AI) model," *Int. J. Hydrogen Energy*, vol. 63, pp. 1–9, Apr. 2024, doi: 10.1016/j.ijhydene.2024.03.120.
- [14] A. Milićević, Z. Marković, S. Belošević, M. Erić, M. Žarković, and A. Marinković, "Influence of fuel and operation mode on air pollutants emission from pulverized coal-fired power plant: Field experiments and ML predictions," *Thermal Science and Engineering Progress*, vol. 57, Jan. 2025, doi: 10.1016/j.tsep.2024.103151.
- [15] W. M. Ashraf, V. Dua, and R. Debnath, "Domain consistent industrial decarbonisation of global coal power plants," *Communications Sustainability*, vol. 1, no. 1, Jan. 2026, doi: 10.1038/s44458-025-00010-w.
- [16] Y. Yin *et al.*, "machine learning-assisted synergetic optimization of carbon emission and thermal efficiency for a 660 MW pulverized coal-fired boiler," *Energy*, vol. 341, Dec. 2025, doi: 10.1016/j.energy.2025.139291.
- [17] X. Liu, H. Yu, H. Liu, and Z. Sun, "Multi-Factor Carbon Emissions Prediction in Coal-Fired Power Plants: A Machine Learning Approach for Carbon Footprint Management," *Energies (Basel)*, vol. 18, no. 7, Apr. 2025, doi: 10.3390/en18071715.
- [18] A. E. Setyawan and B. Sudiarto, "Optimization of Heat Rate and Greenhouse Gas Emission Reduction at Coal-Fired Power Plants in Indonesia Through Machine Learning Modeling," *International Journal of Electrical, Computer, and Biomedical Engineering*, vol. 2, no. 4, Dec. 2024, doi: 10.62146/ijecbe.v2i4.77.
- [19] Y. Zhao, R. Liu, Z. Liu, L. Liu, J. Wang, and W. Liu, "A Review of Macroscopic Carbon Emission Prediction Model Based on Machine Learning," Apr. 01, 2023, *MDPI*. doi: 10.3390/su15086876.
- [20] P. Paramasivam, M. Alruqi, and Ü. Ağbulut, "Experimental simulation and analysis of Acacia Nilotica biomass gasification with XGBoost and SHapley Additive Explanations to determine the importance of key features," *Energy*, vol. 327, Jul. 2025, doi: 10.1016/j.energy.2025.136291.