

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sektor bangunan merupakan salah satu sektor yang telah berkembang pesat seiring dengan pertumbuhan ekonomi, bertambahnya jumlah penduduk, dan tingginya urbanisasi. Semakin meningkatnya kebutuhan bangunan untuk perumahan, industri, fasilitas publik dan berbagai kebutuhan lainnya menjadikan sektor ini sebagai salah satu kontributor terbesar terhadap konsumsi energi. Sektor bangunan saat ini menjadi salah satu penyumbang terbesar konsumsi energi di dunia. Sekitar 40% dari total konsumsi energi global berasal dari bangunan. Bangunan juga secara signifikan turut menyumbang sepertiga dari emisi gas rumah kaca yang menjadi salah satu pemicu fenomena perubahan iklim yang ekstrem [1].

Konsumsi energi bangunan untuk sistem pendinginan ruangan (space cooling) menunjukkan laju peningkatan yang jauh lebih cepat dibandingkan konsumsi energi lainnya. Energi pendinginan bangunan merupakan total energi yang digunakan oleh sistem pendingin bangunan selama periode tertentu untuk menurunkan atau mempertahankan suhu dan kelembapan ruang dalam batas kenyamanan termal. Laporan dari International Energy Agency (2024) menyampaikan bahwa kebutuhan energi untuk pendinginan bangunan diperkirakan akan meningkat lebih dari dua kali lipat dibandingkan laju pertumbuhan rata-rata energi bangunan secara keseluruhan. Sementara itu, selama periode gelombang panas konsumsi energi pendinginan nyatanya menjadi pendorong utama kenaikan permintaan listrik di banyak wilayah [2]. Pada penelitian [3] terkait analisis konsumsi energi gedung komersial, menyebutkan bahwa pada tahun 2021 sektor bangunan di Indonesia mengkonsumsi energi setara 43,48 juta BOE (Barrel of Oil Equivalent) dan mengalami peningkatan menjadi 58,664 juta BOE dan 65,997 juta BOE pada tahun 2022-2023 dengan 62,9-66,3% konsumsi energi berasal dari sistem pendinginan. Tanpa strategi efisiensi energi dan kebijakan yang tepat, fenomena konsumsi energi pendinginan yang terus meningkat berpotensi menimbulkan ketergantungan yang tinggi terhadap energi listrik, peningkatan emisi gas rumah kaca, serta kenaikan biaya operasional bangunan. Upaya dalam

mengurangi konsumsi energi pada bangunan, terutama energi termal menjadi hal yang krusial guna mengurangi dampak buruk perubahan iklim dan mendukung keberlanjutan [4].

Pengembangan model untuk peramalan atau prediksi konsumsi energi menjadi salah satu strategi utama dalam mencapai efisiensi energi untuk mengurangi konsumsi energi jangka panjang. Prediksi konsumsi energi yang akurat menjadi acuan utama dalam menentukan langkah-langkah untuk mencapai pengelolaan energi berkelanjutan [5]. Konsumsi energi untuk kebutuhan pendinginan pada bangunan dipengaruhi oleh interaksi non-linier antar berbagai faktor, seperti kondisi cuaca, karakteristik fisik bangunan, dan pola perilaku penghuni. Kompleksitas hubungan tersebut menimbulkan variasi total konsumsi energi pendinginan yang sulit diprediksi dengan pendekatan komputasi sederhana. Oleh karena itu, diperlukan metode yang mampu mempelajari pola dinamis dan menangkap hubungan kompleks antar faktor agar dapat menghasilkan prediksi yang akurat. Seiring dengan kemajuan pesat di bidang teknologi dan analisis data, pendekatan berbasis Machine Learning (ML) kini dapat menjadi alat yang efektif untuk memprediksi kinerja energi termal pada bangunan [6]. Beberapa penelitian sebelumnya telah menerapkan model ML untuk memprediksi konsumsi energi pendinginan bangunan dengan berbagai pendekatan. Penelitian oleh [7] mengembangkan model short-term forecasting berbasis Artificial Neural Network (ANN) dan Support Vector Machine (SVM) untuk memperkirakan beban pendinginan pada bangunan hotel selama periode musim panas. Hasil menunjukkan bahwa model ANN memberikan performa terbaik dengan nilai $r=0,93$, WAPE sebesar 19,93%, dan CV sebesar 27,03%. Penelitian ini menegaskan bahwa model ANN lebih adaptif terhadap hubungan non-linear antar variabel dibandingkan SVM. Penelitian lain oleh [8] mengembangkan model prediksi konsumsi energi pendinginan pada gedung perkantoran menggunakan 4 jenis model ML dengan mempertimbangkan faktor perilaku penghuni (occupant behavior). Hasilnya menunjukkan bahwa dari 4 model yang digunakan meliputi Classification and Regression Tree (CART), Ensemble Bagging Tree (EBT), Artificial Neural Network (ANN), dan Deep Neural Network (DNN), model DNN dengan empat hidden layer memberikan performa terbaik dengan CV sebesar 2,97% dan R^2

sebesar 0,9996. Selain itu, dari hasil penelitian [8] menunjukkan bahwa model DNN terbukti lebih unggul pada dataset besar, sedangkan model ensemble lebih efisien pada dataset kecil. Penelitian lain oleh [9] mengembangkan model prediksi konsumsi energi pendinginan pada bangunan residensial berdasarkan data tagihan listrik dan cuaca berskala besar. Dataset yang digunakan berasal dari proyek Pecan Street Inc. di tiga kota Amerika Serikat yang mencakup data energi pendinginan bulanan dari beberapa rumah. Beberapa algoritma diterapkan yaitu GLM, KNN, SVM, RF, dan Extreme Gradient Boosting (XGBoost), dan Ranger Regression. Hasilnya menunjukkan bahwa model Extreme Gradient Boosting (XGBoost) memberikan performa terbaik dengan nilai R^2 sebesar 0,97 pada training dan 0,92 pada cross validation. Dari penelitian-penelitian [7], [8], dan [9] terlihat bahwa fokus penelitian yang dilakukan masih terbatas pada jenis bangunan tertentu, seperti hotel, gedung perkantoran, dan rumah tinggal. Keterbatasan tersebut menyebabkan model yang dikembangkan cenderung hanya optimal pada kondisi operasional dan pola penggunaan energi yang serupa. Penelitian lebih lanjut dengan memperluas cakupan model prediksi ke beragam jenis bangunan diperlukan untuk meningkatkan generalisasi dan keandalan model.

Berbagai algoritma ML seperti ANN, SVM, DNN, dan XGBoost telah dieksplorasi. Namun, algoritma-algoritma ini sering kali memiliki keterbatasan dalam hal stabilitas, kebutuhan data, dan efisiensi komputasi. Artificial Neural Network (ANN) sering membutuhkan jumlah data yang besar serta rentan terhadap overfitting [10]. Meskipun Support Vector Machine (SVM) mampu menangkap pola non-linier dengan baik, kinerjanya dapat menurun pada skenario dengan banyak fitur dan variabel kategorikal serta ketika data observasi terbatas [11]. DNN membutuhkan jumlah data yang besar, waktu pelatihan yang lama, serta pengaturan banyak hyperparameter sehingga proses training menjadi kompleks dan kurang efisien pada skenario data yang terbatas [12]. Sementara itu, algoritma boosting seperti XGBoost telah menunjukkan performa tinggi dalam banyak kasus, tapi pengaplikasiannya masih memerlukan proses feature engineering yang cermat untuk menangani fitur kategorikal [13]. Model berbasis Ensemble learning, khususnya Gradient Boosting (GB) telah menunjukkan performa yang kuat pada banyak kasus. Diantara berbagai jenis model GB, CatBoost (Categorical Boosting)

paling menonjol sebagai algoritma yang memiliki kinerja kompetitif serta kemampuan pemodelan yang konsisten pada data tabular. Catboost dirancang khusus untuk menangani fitur kategorikal secara otomatis. CatBoost mampu mencapai akurasi prediksi yang tinggi dengan waktu pelatihan yang lebih cepat dibandingkan algoritma boosting lainnya seperti XGBoost atau LightGBM [14]. CatBoost adalah salah satu algoritma berbasis Ensemble Learning yang stabil, efisien, dan praktis. Penelitian yang dilakukan oleh [15] menunjukkan bahwa penerapan CatBoost dalam memprediksi konsumsi energi bangunan mampu menghasilkan model prediksi dengan nilai R^2 sebesar 0,897, akurasi deteksi outlier 99,32%, dan performa lebih tinggi dibandingkan model prediksi dengan RF dan Gradient Boosting. Penelitian lain oleh [16] juga menunjukkan bahwa model CatBoost cukup unggul dalam mendeteksi akun yang diretas dengan perolehan akurasi tertinggi dibandingkan model deteksi menggunakan Adaptive Boosting (AdaBoost) dan XGBoost. Penelitian lainnya oleh [17] yang juga menerapkan CatBoost sebagai model prediksi pada kasus kestabilan lereng, menunjukkan hasil bahwa model CatBoost secara konsisten menghasilkan performa klasifikasi yang lebih tinggi dibandingkan model dengan metode Support Vector Machine (SVM), LightGBM, dan Logistic Regression (LR). Penelitian-penelitian tersebut menunjukkan bahwa CatBoost memiliki fleksibilitas dan kemampuan generalisasi yang tinggi dalam berbagai aplikasi, baik pada kasus regresi maupun klasifikasi serta mampu mengungguli banyak algoritma pembanding lainnya secara konsisten. Namun, kinerja model CatBoost sangat bergantung pada pemilihan nilai hyperparameter yang optimal. Salah satu solusi efektif untuk pemilihan hyperparameter ini adalah dengan memanfaatkan algoritma optimasi untuk menemukan hyperparameter yang optimal [18].

Algoritma metaheuristik telah menjadi salah satu algoritma yang cukup banyak diterapkan dalam bidang optimasi. Dalam kasus pengoptimalan model CatBoost, algoritma metaheuristik dapat digunakan dalam menemukan solusi terbaik pada ruang pencarian yang besar sehingga dapat meningkatkan akurasi dan efisiensi model [19]. Beberapa penelitian sebelumnya telah mengeksplorasi berbagai algoritma metaheuristik untuk meningkatkan performa model CatBoost. Algoritma Red Fox Optimization (RFOA) yang diterapkan pada penelitian [20]

untuk optimasi hyperparameter CatBoost pada deteksi anomali klaim kartu kredit menunjukkan akurasi 99,959% serta metrik presisi, recall, AUC, dan F1-score tertinggi di antara metode pembandingan seperti CatBoost, RF, XGBoost, dan ECOD. Penerapan Dingo Optimization Algorithm (DOA) untuk optimasi CatBoost pada penelitian [21] untuk peramalan permintaan pada beberapa toko *e-commerce* berhasil meningkatkan akurasi peramalan permintaan sebesar 0,52 sampai 15,94% sekaligus mengurangi biaya transportasi hingga 6,67% dibandingkan ARIMA, LSTM, Deep Neural Network (DNN), CatBoost, SVM, dan LSTM-CatBoost. Algoritma Snake Optimization (SO) untuk optimasi CatBoost pada penelitian [22] dalam kasus peramalan beban listrik mampu menghasilkan performa yang lebih unggul dibanding model lain yang menggunakan Back Propagation Neural Network.

Meskipun pada penelitian-penelitian yang telah disebutkan penerapan berbagai algoritma metaheuristik telah menunjukkan performa yang sangat baik dalam meningkatkan performa CatBoost, masih terdapat ruang untuk penelitian lebih lanjut dengan mengeksplorasi algoritma metaheuristik lain yang mampu menawarkan keunggulan lebih besar dalam kecepatan konvergensi dan akurasi, seperti dengan menggunakan algoritma Emperor Penguin Optimizer (EPO). Dengan mekanisme pencarian solusi yang terinspirasi dari perilaku berkerumun oleh penguin kaisar untuk bertahan hidup di lingkungan yang ekstrem, algoritma EPO telah terbukti memiliki kinerja yang sangat menjanjikan dalam menangani masalah optimasi [23]. Penelitian oleh [23] menerapkan EPO untuk mengoptimalkan parameter XGBoost (EPO-XGBoost) dalam mengklasifikasikan kanker payudara dan diabetes. Hasil penelitiannya menunjukkan bahwa EPO-XGBoost memberikan kinerja yang lebih baik dibanding model XGBoost, PSO-XGBoost, dan FA-XGBoost. Penelitian lainnya oleh [24] yang menggunakan algoritma EPO untuk mengoptimalkan bobot dan bias pada model Feed-Forward Neural Network (FNN) dalam memprediksi konsumsi energi pasca-retrofit juga menunjukkan hasil bahwa model FNN-EPO memberikan kinerja prediktif lebih baik daripada model FNN biasa dengan peningkatan akurasi sekitar 46%. Algoritma EPO telah banyak digunakan karena efisien dalam pencarian solusi yang optimal. Namun, kemampuannya masih rentan terhadap stagnasi pada solusi lokal.

Penelitian terbaru oleh [25] memperkenalkan Self-Adaptive Emperor Penguin Optimizer (SA-EPO) sebagai pengembangan terbaru dari EPO klasik. SA-EPO mengatasi kekurangan EPO klasik yang cenderung stagnan karena parameter statis dengan mekanisme adaptasi multi strategi yang memungkinkan penyesuaian parameter secara dinamis berdasarkan kualitas solusi. Pendekatan ini meningkatkan keseimbangan eksplorasi dan eksploitasi algoritma sekaligus mempercepat konvergensi menuju solusi optimal. Penerapan SA-EPO untuk mengoptimalkan model CatBoost menawarkan peluang baru dalam memberikan kontribusi signifikan terhadap pengembangan metode prediksi energi yang lebih akurat dan efisien.

Berdasarkan latar belakang tersebut, penelitian yang akan dilakukan oleh peneliti ialah mengembangkan model prediksi konsumsi energi pendinginan bangunan menggunakan CatBoost dan SA-EPO. Fokus utama penelitian adalah menguji kinerja CatBoost dalam memprediksi total konsumsi energi pendinginan bangunan dengan cakupan analisis terhadap jenis bangunan yang lebih beragam. Selain itu, optimasi hyperparameter menggunakan algoritma SA-EPO diterapkan untuk meningkatkan akurasi prediksi. Penelitian ini diharapkan dapat memberikan wawasan baru dan solusi yang inovatif dalam pengembangan metode prediksi dengan kemampuan generalisasi yang lebih kuat dan akurat serta dapat memberikan kontribusi positif terhadap pengembangan ilmu pengetahuan di bidang optimasi dan Machine Learning.

1.2 Rumusan Masalah

Adapun rumusan masalah berdasarkan permasalahan dari latar belakang yang telah diuraikan adalah sebagai berikut :

1. Bagaimana kinerja model CatBoost dalam memprediksi konsumsi energi pendinginan pada bangunan?
2. Bagaimana penerapan optimasi hyperparameter dengan algoritma SA-EPO untuk meningkatkan performa CatBoost dalam memprediksi konsumsi energi pendinginan pada bangunan?
3. Bagaimana pengaruh optimasi hyperparameter menggunakan algoritma SA-EPO terhadap performa CatBoost dalam memprediksi konsumsi energi pendinginan pada bangunan?

4. Bagaimana hasil yang diperoleh dari model CatBoost yang dioptimasi dengan algoritma SA-EPO dibandingkan dengan model CatBoost yang dioptimasi menggunakan algoritma metaheuristik lain yang telah digunakan pada penelitian-penelitian sebelumnya?

1.3 Tujuan Penelitian

Berdasarkan permasalahan yang telah diuraikan, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut :

1. Menganalisis potensi dan kemampuan model CatBoost dalam memprediksi konsumsi energi pendinginan pada bangunan.
2. Mengetahui proses penerapan algoritma SA-EPO untuk optimasi hyperparameter CatBoost
3. Menganalisis pengaruh penerapan algoritma SA-EPO dalam mengoptimalkan hyperparameter CatBoost untuk meningkatkan performa prediksi.
4. Menganalisis perbandingan hasil dari model CatBoost yang dioptimasi dengan algoritma SA-EPO dan model CatBoost yang dioptimasi menggunakan algoritma metaheuristik lain yang telah digunakan pada penelitian-penelitian sebelumnya.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat bagi banyak pihak, adapun manfaat dari penelitian ini secara rinci, yaitu :

1. Bagi Akademisi dan Peneliti
Penelitian ini memberikan kontribusi terhadap literatur ilmiah di bidang penerapan algoritma machine learning dalam kasus pengelolaan energi. Penelitian ini dapat membuka peluang baru untuk penelitian lebih lanjut, terutama dalam pengoptimalan model prediksi pada aplikasi yang lain.
2. Bagi Praktisi di Sektor Bangunan
Penelitian ini memberikan alternatif metode prediksi energi yang efisien, akurat, dan adaptif untuk diterapkan pada berbagai jenis bangunan. Hasil penelitian ini dapat membantu praktisi di sektor bangunan dalam merancang

bangunan yang hemat energi dan ramah lingkungan dengan mempertimbangkan perkiraan jumlah konsumsi energi yang terpakai.

3. Bagi Masyarakat

Penelitian ini berkontribusi pada upaya global untuk mengatasi dampak buruk perubahan iklim dan meningkatkan kelestarian lingkungan. Dengan meningkatkan efisiensi energi bangunan, masyarakat dapat mengurangi biaya konsumsi listrik, mendapatkan lingkungan hunian yang hemat energi, dan melestarikan lingkungan. Secara tidak langsung, manfaat ini dapat meningkatkan kualitas hidup dan kesejahteraan masyarakat secara keseluruhan.

1.5 Batasan Masalah

Adapun batasan-batasan masalah yang ditetapkan untuk menjelaskan ruang lingkup dan fokus analisis pada penelitian ini, yaitu :

1. Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari data *open source* di internet. Dataset diperoleh dari Mendeley Data.
2. Penelitian ini hanya memfokuskan pengembangan model prediksi untuk konsumsi energi pendinginan bangunan. Konsumsi energi lainnya seperti pemanasan, pencahayaan, dan peralatan listrik tidak termasuk objek yang dianalisis dalam penelitian ini.
3. Model prediksi utama yang digunakan dalam penelitian ini adalah model CatBoost yang dioptimalkan hyperparameter-nya dengan algoritma SA-EPO. Sebagai evaluasi tambahan, beberapa algoritma optimasi lain juga akan diterapkan untuk dibandingkan dengan kinerja algoritma SA-EPO sehingga dapat diketahui sejauh mana tingkat peningkatan performa model CatBoost yang dihasilkan oleh SA-EPO dibanding algoritma optimasi lain.