



SNESTIK

Seminar Nasional Teknik Elektro, Sistem Informasi,
dan Teknik Informatika

<https://ejurnal.itats.ac.id/snestik> dan <https://snestik.itats.ac.id>



Informasi Pelaksanaan :

SNESTIK V - Surabaya, 26 April 2025

Fakultas Teknik Elektro dan Teknologi Informasi, Institut Teknologi Adhi Tama Surabaya

Informasi Artikel:

DOI : 10.31284/p.snestik.2025.7578

Prosiding ISSN 2775-5126

Fakultas Teknik Elektro dan Teknologi Informasi-Institut Teknologi Adhi Tama Surabaya

Gedung A-ITATS, Jl. Arief Rachman Hakim 100 Surabaya 60117 Telp. (031) 5945043

Email : snestik@itats.ac.id

Optimasi Parameter Operasional Mini Pembangkit Listrik Tenaga Angin Berbasis Machine Learning untuk Meningkatkan Output Daya

Parman, Fais Hamzah, Rahmat Basya Shahrays Tsany, Dicki Nizar Zulfika, Thomas Brian

Jurusan Teknik Bangunan Kapal, Politeknik Perkapalan Negeri Surabaya

e-mail: parman@ppns.ac.id

ABSTRACT

The utilization of renewable energy is experiencing significant growth, with wind turbines emerging as a key solution for generating environmentally friendly electricity. However, the efficiency of wind turbines is highly dependent on their operational parameters, such as wind speed, blade size, angular velocity, and torque. This research aims to optimize the operational parameters of small-scale wind turbines using an XGBoost-based Machine Learning model and an L-BFGS-B algorithm-based optimization method. A simulation dataset was generated based on the physical equations of wind turbine power and a MATLAB Simulink model, incorporating added noise to approximate real-world conditions. The XGBoost model was trained to predict the turbine's output power based on its operational parameters. Subsequently, an optimization method was employed to identify the parameter combination that yields maximum power. The experimental results demonstrate that the model exhibits strong performance, characterized by a low Mean Squared Error (MSE) and a high R-squared score. The optimization process successfully achieved a significant increase in power output compared to the initial configuration. Through this approach, wind turbine systems can operate more efficiently and generate optimal electrical power. This study contributes to the advancement of artificial intelligence-based optimization strategies for renewable energy systems.

Keywords: Wind turbine, optimization, Machine Learning, XGBoost, L-BFGS-B.

ABSTRAK

Penggunaan energi terbarukan semakin berkembang, dan turbin angin menjadi salah satu solusi utama dalam menghasilkan listrik secara ramah lingkungan. Namun, efisiensi turbin angin sangat bergantung pada parameter operasionalnya seperti kecepatan angin, ukuran bilah, kecepatan sudut, dan torsi. Penelitian ini bertujuan untuk mengoptimalkan parameter operasional turbin angin skala kecil menggunakan model Machine Learning berbasis XGBoost serta metode optimasi berbasis algoritma L-BFGS-B. Dataset simulasi dibuat berdasarkan persamaan fisika daya turbin angin dan model MATLAB Simulink dengan tambahan noise untuk mendekati kondisi nyata. Model XGBoost dilatih untuk memprediksi daya keluaran turbin berdasarkan parameter operasionalnya. Selanjutnya, metode optimasi digunakan untuk mencari kombinasi parameter yang menghasilkan daya

maksimum. Hasil eksperimen menunjukkan bahwa model memiliki performa yang baik dengan nilai Mean Squared Error (MSE) yang rendah dan skor R-squared yang tinggi. Optimasi yang dilakukan berhasil meningkatkan output daya secara signifikan dibandingkan dengan konfigurasi awal. Dengan pendekatan ini, sistem turbin angin dapat beroperasi secara lebih efisien dan menghasilkan daya listrik yang optimal. Studi ini memberikan kontribusi dalam pengembangan strategi optimasi berbasis kecerdasan buatan untuk sistem energi terbarukan.

Kata kunci: Turbin angin, optimasi, Machine Learning, XGBoost, L-BFGS-B


PENDAHULUAN

Mini turbin angin merupakan salah satu solusi yang menjanjikan dalam pemanfaatan energi terbarukan, khususnya dalam konteks pengurangan ketergantungan pada sumber energi fosil dan mitigasi perubahan iklim. Di antara berbagai sumber energi terbarukan yang tersedia, tenaga angin telah muncul sebagai salah satu teknologi yang paling menjanjikan dan berkembang pesat dalam transisi energi global. Peningkatan kapasitas pembangkit listrik tenaga angin telah tumbuh pesat dalam beberapa tahun terakhir, didorong oleh dukungan kebijakan dan penurunan biaya yang signifikan, terutama untuk teknologi fotovoltaik surya dan tenaga angin. Pada tahun 2023, kapasitas total tenaga angin terpasang secara global mencapai 1015 GW, dengan 93% merupakan instalasi di darat dan 7% di lepas pantai. Pembangkitan listrik tenaga angin global mencapai lebih dari 2330 TWh pada tahun 2023, meningkat 10% dari tahun sebelumnya, menjadikannya teknologi terbarukan non-hidro terkemuka[1]. Namun, perancangan pembangkit listrik tenaga angin (PLTB) skala kecil masih jarang dilakukan sehingga perlu dilakukan optimasi PLTB menggunakan perangkat lunak Matlab Simulink. Perancangan PLTB menggunakan Simulink merupakan langkah awal dalam pengembangan sistem energi terbarukan yang efisien. Model MATLAB Simulink tidak cukup baik untuk optimasi parameter sehingga dibutuhkan metode lain untuk melakukan optimasi sesuai dengan parameter terancang di MATLAB Simulink.


Dalam beberapa tahun terakhir, teknik pembelajaran mesin (*machine learning*) telah muncul sebagai pendekatan yang menjanjikan untuk mengatasi tantangan-tantangan dan meningkatkan kinerja berbagai sistem teknik, termasuk pembangkit listrik tenaga angin. Pembelajaran mesin memungkinkan sistem untuk belajar dari data, mengidentifikasi pola, dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit. Efektivitas XGBoost telah diakui secara luas, terutama kemampuannya dalam menangani nilai-nilai yang hilang dan mencapai akurasi prediksi yang lebih tinggi dibandingkan dengan model-model pembelajaran mesin tradisional, seperti Random Forests dan Support Vector Machines [2], [3]. Namun, penting untuk mengakui bahwa meskipun XGBoost memiliki banyak hyperparameter, penyetelan parameter-parameter ini seringkali tidak trivial dan dapat secara signifikan mempengaruhi kinerja model. Optimasi hyperparameter memerlukan strategi yang kuat untuk menavigasi ruang pencarian yang luas, karena ruang parameter yang besar dapat menyebabkan peningkatan waktu komputasi untuk pengembangan model [4]. Pendekatan saat ini, termasuk optimasi Bayesian dan Particle Swarm Optimization, telah menunjukkan hasil yang menjanjikan dalam meningkatkan kinerja XGBoost; namun, masih terdapat celah dalam penerapan algoritma yang dirancang khusus untuk optimasi konveks seperti L-BFGS-B, yang berpotensi lebih menyederhanakan proses penyetelan hyperparameter dan efisiensi komputasi terkait[5][6]. Penelitian ini bertujuan untuk mengatasi kebutuhan akan strategi optimasi berbasis pembelajaran mesin yang efektif untuk meningkatkan keluaran daya pembangkit listrik tenaga angin mini karena daya yang dihasilkan oleh PLTB sering tidak sesuai dengan kebutuhan beban, maka perlu melakukan optimasi sebelum pembuatan prototipe dengan memanfaatkan metode optimasi tersebut.

METODE

Alur penelitian dimulai dengan identifikasi masalah dan kajian pustaka untuk memahami konteks dan solusi yang ada. Selanjutnya, model Matlab Simulink dibuat dan dijalankan untuk menghasilkan data simulasi. Data ini kemudian diproses dan digunakan untuk melatih model XGBoost Regressor. Model yang telah dilatih dievaluasi dan jika valid, parameternya dioptimalkan. Hasil dari model yang dioptimalkan dianalisis untuk menarik kesimpulan yang relevan dengan masalah penelitian. Proses ini diakhiri dengan penarikan kesimpulan yang merangkum temuan utama dari penelitian.



Gambar 1. Diagram alir penelitian




Gambar 2. Diagram alir preprocessing data dan validasi

Preprocessing adalah tahap awal dalam pipeline machine learning yang bertujuan untuk mempersiapkan data agar sesuai dengan kebutuhan model. Dalam penelitian ini, preprocessing melibatkan data mentah dari hasil Model MATLAB Simulink dan pemisahan antara fitur (input) dan target (output), diikuti dengan pembagian data menjadi data latih dan uji (80:20). Setelah itu, seluruh fitur distandarkan menggunakan StandardScaler agar memiliki skala yang sama (mean = 0, std = 1). Ini penting karena model seperti XGBoost dan metode optimasi lebih sensitif terhadap perbedaan skala antar fitur.

Setelah preprocessing, model XGBoost dilatih menggunakan data latih. Kinerja model kemudian divalidasi menggunakan data uji yang tidak pernah dilihat oleh model sebelumnya. Evaluasi dilakukan menggunakan R^2 Score (mengukur seberapa baik model menjelaskan varians data) dan Mean Squared Error (mengukur rata-rata kesalahan prediksi). Skor R^2 sebesar 0.7 menunjukkan bahwa model cukup baik dalam memprediksi daya keluaran turbin berdasarkan input yang diberikan [7].

HASIL DAN PEMBAHASAN

Optimasi output daya Pembangkit Listrik Tenaga Bayu (PLTB) skala kecil dapat dilakukan dengan pendekatan berbasis machine learning menggunakan model XGBoost Regressor yang telah diimplementasikan sebelumnya. Berdasarkan hasil simulasi model MATLAB Simulink pada tabel 1, daya listrik (P_m) yang dihasilkan bervariasi tergantung pada kecepatan angin, ukuran rotor (R), kecepatan sudut (ω), dan torsi (T). Pada kondisi awal dengan kecepatan angin 7,7 m/s, ukuran blade 0,606 m, kecepatan sudut 88,94 rad/s, dan torsi 1,41 Nm, daya listrik yang dihasilkan sebesar 125,8 watt. Model machine learning digunakan untuk mempelajari hubungan antara parameter ini dan memprediksi daya optimal yang dapat dihasilkan dengan kombinasi parameter yang lebih baik.



Gambar 3. Model PLTB mini di Matlab Simulink

Pendekatan optimasi dilakukan dengan menggunakan metode L-BFGS-B (*Limited-memory Broyden-Fletcher-Goldfarb-Shanno with Box constraints*) untuk menentukan kombinasi parameter operasional yang memaksimalkan output daya berdasarkan model XGBoost. Algoritma ini mencari kombinasi optimal dengan meminimalkan nilai negatif dari prediksi daya keluaran. Setelah dilakukan optimasi, diperoleh kombinasi kecepatan angin, ukuran blade, kecepatan sudut, dan torsi yang lebih optimal dibandingkan dengan konfigurasi awal. Model XGBoost, yang telah dilatih dengan data hasil simulasi MATLAB, memastikan bahwa optimasi dilakukan berdasarkan pola hubungan yang valid dari parameter masukan terhadap daya keluaran.

Tabel 1. Hasil simulasi model MATLAB Simulink

Kecepatan Angin (m/s)	R (m)	ω (rad/s)[8], [9]	Torsi (Nm)	P_m (watt)
2	0,606	8,69	0,0082	0,071
3		22,39	0,14	3,18
4		30,46	0,26	8
5		39,15	0,43	16,96
6		69,31	0,86	59,52
7		80,86	1,17	94,52
7,7		88,94	1,41	125,8
8		92,41	1,53	141,1

Kecepatan Angin (m/s)	R (m)	ω (rad/s)[8], [9]	Torsi (Nm)	P_m (watt)
9		103,96	1,93	200,9
10		115,51	2,39	275,76
11		127,06	2,89	366,8
12		138,61	3,44	476,2

Luaran optimasi menunjukkan bahwa dengan menyesuaikan parameter operasional, daya listrik yang dihasilkan dapat meningkat dibandingkan dengan nilai awal 125,8 watt. Evaluasi model menggunakan Mean Squared Error (MSE) dan R-squared (R^2) memastikan bahwa prediksi memiliki tingkat akurasi yang baik. Jika nilai MSE rendah dan R^2 mendekati 1, maka model dapat diandalkan dalam melakukan optimasi. Nilai R^2 dari model machine learning ini adalah 0.79 yang artinya model sudah cukup baik menjelaskan semua variabilitas dalam data. Dengan demikian, pendekatan ini memberikan solusi berbasis data yang lebih akurat dibandingkan dengan metode konvensional, sehingga dapat digunakan untuk meningkatkan efisiensi PLTB skala kecil dalam berbagai kondisi kecepatan angin.

```
In [48]: # Optimasi input untuk memaksimalkan daya output
def objective_function(params):
    params_scaled = scaler.transform([params])
    return -model.predict(params_scaled)[0] # Negatif karena minimize digunakan

# Batasan input
bounds = [(2, 12), (0.3, 0.65), (10, 150), (0.14, 2.0)] # (kecepatan_angin, ukuran_blade, kecepatan_sudut, torsi)
initial_guess = [10, 0.4, 75, 1]

result = minimize(objective_function, initial_guess, bounds=bounds, method='L-BFGS-B')
optimal_input = result.x
optimal_input_scaled = scaler.transform([optimal_input])
optimal_power = model.predict(optimal_input_scaled)

print(f'Optimal Input: Kecepatan Angin={optimal_input[0]:.2f}, Ukuran Blade={optimal_input[1]:.3f}, Kecepatan Sudut={optimal_in
print(f'Prediksi daya optimal: {optimal_power[0]:.2f} Watt')

Optimal Input: Kecepatan Angin=10.00, Ukuran Blade=0.400, Kecepatan Sudut=75.00, Torsi=1.00
Prediksi daya optimal: 139.34 Watt
```

Gambar 4. Hasil optimasi model mini PLTB

Gambar 3 menjelaskan tentang proses untuk mengoptimasi parameter operasional turbin angin guna memaksimalkan output daya listrik. Objective Function menggunakan model XGBoost yang telah dilatih untuk memprediksi daya berdasarkan parameter input, lalu mengembalikan nilai negatifnya agar dapat digunakan dalam metode optimasi L-BFGS-B, yang bekerja dengan pendekatan minimisasi. Batasan input diberikan untuk memastikan bahwa solusi yang diperoleh tetap berada dalam rentang realistis, yaitu kecepatan angin (2-12 m/s), ukuran blade (0,3-0,65 m), kecepatan sudut (10-150 rad/s), dan torsi (0,14-2,0 Nm). Nilai awal optimasi dipilih sebagai (10, 0.4, 75, 1.0) untuk memulai proses pencarian solusi optimal dalam ruang parameter yang diberikan.

Hasil optimasi menunjukkan bahwa kombinasi optimal parameter operasional untuk menghasilkan daya listrik tertinggi dalam model ini adalah kecepatan angin 10 m/s, ukuran blade 0,4 m, kecepatan sudut 75 rad/s, dan torsi 1 Nm, yang memprediksi output daya sebesar 139,34 Watt. Dibandingkan dengan konfigurasi awal sebesar 125,8 Watt, pendekatan ini menunjukkan peningkatan efisiensi sistem turbin angin. Dengan menerapkan teknik optimasi berbasis machine learning, sistem dapat menyesuaikan parameter operasionalnya secara otomatis untuk mencapai kinerja optimal dalam kondisi lingkungan tertentu. Pendekatan ini dapat diterapkan lebih lanjut dalam sistem kontrol real-time guna meningkatkan efisiensi turbin angin di berbagai kondisi kecepatan angin.

KESIMPULAN

Optimasi output daya PLTB skala kecil melalui pendekatan *machine learning* dengan model XGBoost Regressor dan metode L-BFGS-B telah menunjukkan hasil yang menjanjikan. Optimasi ini menghasilkan peningkatan daya listrik dari 125,8 Watt menjadi 139,34 Watt dengan kombinasi parameter operasional yang optimal. Dengan demikian, pendekatan ini tidak hanya memberikan solusi berbasis data yang lebih akurat dibandingkan metode konvensional, tetapi juga memiliki potensi besar untuk diterapkan dalam sistem kontrol real-time, memungkinkan turbin angin untuk secara otomatis menyesuaikan parameter operasionalnya dan mencapai kinerja optimal dalam berbagai kondisi lingkungan.

DAFTAR PUSTAKA

- [1] IEA, “Wind,” IEA. Accessed: Mar. 25, 2025. [Online]. Available: <https://www.iea.org/energy-system/renewables/wind>
- [2] A. Hakam, W. Utama, S. A. Garini, O. A. Jabar, A. N. F. Insani, and Y. Rosandi, “Sonic Log Prediction Based on Extreme Gradient Boosting (XGBoost) Machine Learning Algorithm by Using Well Log Data,” *BIO Web Conf*, vol. 89, p. 09003, Jan. 2024, doi: 10.1051/bioconf/20248909003.
- [3] D. N. Gono, H. Napitupulu, and Firdaniza, “Silver Price Forecasting Using Extreme Gradient Boosting (XGBoost) Method,” *Mathematics*, vol. 11, no. 18, p. 3813, Sep. 2023, doi: 10.3390/math11183813.
- [4] H. Wedagedara, C. Witharana, R. Fahey, D. Cerrai, J. Parent, and A. S. Perera, “Non-Parametric Machine Learning Modeling of Tree-Caused Power Outage Risk to Overhead Distribution Powerlines,” *Applied Sciences*, vol. 14, no. 12, p. 4991, Jun. 2024, doi: 10.3390/app14124991.
- [5] H. A. Al-Jamimi, “Synergistic Feature Engineering and Ensemble Learning for Early Chronic Disease Prediction,” *IEEE Access*, vol. 12, pp. 62215–62233, 2024, doi: 10.1109/ACCESS.2024.3395512.
- [6] I. D. Mienye and N. Jere, “Optimized Ensemble Learning Approach with Explainable AI for Improved Heart Disease Prediction,” *Information*, vol. 15, no. 7, p. 394, Jul. 2024, doi: 10.3390/info15070394.
- [7] P. Alves *et al.*, “Validation of a machine learning approach to estimate Systemic Lupus Erythematosus Disease Activity Index score categories and application in a real-world dataset,” *RMD Open*, vol. 7, no. 2, p. e001586, May 2021, doi: 10.1136/rmdopen-2021-001586.
- [8] Kusnadi and Ismail, “Eksperimental Turbin Zephyr dengan Pengaruh Sudu Rotor dan Sudu Statis,” *Rotasi*, vol. 25, pp. 33–39, Jul. 2023, Accessed: Feb. 16, 2025. [Online]. Available: <https://ejournal.undip.ac.id/index.php/rotasi/article/download/58171/24528>
- [9] H. Slah, D. Mehdi, and S. Lassaad, “Advanced Control of a PMSG Wind Turbine,” *International Journal of Modern Nonlinear Theory and Application*, vol. 05, no. 01, pp. 1–10, 2016, doi: 10.4236/ijmnta.2016.51001.

Halaman ini sengaja ditambahkan