

Proyeksi Kebutuhan Energi Listrik Menggunakan Model Hibrida ARIMA dan Regresi Ridge

Pradhipta Seno Respati Parlinto, S.T.¹, Dr.-Ing. Eko Adhi Setiawan, S.T., M.T.¹

¹Jurusan Teknik Sistem Energi, Universitas Indonesia

Email : senorespati@gmail.com (P.S.R), ekoas@eng.ui.ac.id (E.A.S)

Abstrak : Perencanaan sistem energi yang efektif membutuhkan proyeksi kebutuhan energi yang andal, stabil, dan mudah diterapkan, khususnya dalam konteks keterbatasan data historis dan sumber daya komputasi. Namun, banyak pendekatan berbasis kecerdasan buatan yang tersedia saat ini cenderung kompleks, sulit diinterpretasikan, dan memerlukan waktu pengembangan yang panjang, sehingga kurang efisien bagi mahasiswa dan peneliti yang ingin berfokus pada perumusan solusi sistem energi. Penelitian ini mengusulkan pendekatan pemodelan proyeksi kebutuhan energi menggunakan kombinasi metode statistik dan machine learning yang sederhana namun andal, yaitu Auto Regressive Integrated Moving Average (ARIMA) dan Ridge Regression. Model ARIMA digunakan untuk menangkap dinamika temporal konsumsi energi dan membentuk skenario dasar business as usual (BAU) berdasarkan tren historis. Selanjutnya, hasil proyeksi ARIMA dimanfaatkan sebagai input dalam model Ridge Regression untuk memodelkan hubungan multivariat antara konsumsi energi dan faktor socio-ekonomi yang saling berkorelasi. Hasil pengujian menunjukkan bahwa ARIMA mampu merepresentasikan pola historis secara konsisten, namun menghasilkan proyeksi yang relatif konservatif. Sebaliknya, Ridge Regression memberikan estimasi yang lebih stabil dan robust pada kondisi multikolinearitas tinggi serta ukuran data yang terbatas. Integrasi kedua metode ini menghasilkan kerangka pemodelan yang efisien, interpretatif, dan mudah direplikasi. Pendekatan yang diusulkan diharapkan dapat membantu mahasiswa dan peneliti menghemat waktu dalam proses peramalan energi, sehingga dapat lebih fokus pada analisis solusi dan perencanaan sistem energi yang berkelanjutan.

Kata Kunci : ARIMA, Machine Learning, Proyeksi Kebutuhan Energi, Ridge Regression

Abstract : Effective energy system planning requires energy demand projections that are reliable, stable, and easy to implement, particularly under conditions of limited historical data and computational resources. However, many existing artificial intelligence-based forecasting approaches are highly complex, difficult to interpret, and time-consuming to develop, which reduces their practicality for students and researchers who aim to focus on solution-oriented energy system analysis. This paper

Jurnal Energi Baru & Terbarukan, 2026, Vol. 7, No. 2, pp 1 – 7

Received : 12 Februari 2026

Accepted : 15 April 2026

Published : 21 Mei 2026



Copyright: © 2022 by the authors. [Jurnal Energi Baru dan Terbarukan](#) (p-ISSN: [2809-5456](#) and e-ISSN: [2722-6719](#)) published by Master Program of Energy, School of Postgraduate Studies. This article is an open access article distributed under the terms and condition of the [Creative Commons Attribution-ShareAlike 4.0 International License](#) (CC BY-SA 4.0).

proposes a simple yet reliable energy demand projection framework by combining statistical time series modeling and machine learning methods, namely Auto Regressive Integrated Moving Average (ARIMA) and Ridge Regression. The ARIMA model is employed to capture the temporal dynamics of energy consumption and to construct a business-as-usual (BAU) scenario based on historical trends. The ARIMA projections are subsequently used as inputs for the Ridge Regression model, which captures the multivariate relationships between energy demand and correlated socio-economic factors. The results indicate that ARIMA effectively represents historical consumption patterns but tends to produce conservative projections. In contrast, Ridge Regression provides more stable and robust estimates under conditions of high multicollinearity and limited sample size. The integration of these two methods results in an efficient, interpretable, and easily reproducible modeling framework. The proposed approach is intended to help students and researchers reduce the time required for energy demand forecasting, allowing them to focus more on solution development and sustainable energy system planning.

Keywords : ARIMA, Energy Demand Projection, Machine Learning, Ridge Regression

1. Pendahuluan

Peningkatan kebutuhan energi listrik merupakan dampak langsung dari pertumbuhan jumlah penduduk, ekspansi aktivitas ekonomi, dan peningkatan kesejahteraan masyarakat (Fahria, I., & Stevanus, 2022). Pada skala regional, penyusunan rencana penyediaan energi menghadapi tantangan berupa keterbatasan data historis (Auret, C., & Bekker, 2025), ketidakpastian struktural (Fu, Y. et al., 2021), serta kebutuhan akan hasil proyeksi yang mudah dipahami oleh pengambil kebijakan (Samimi, et al., 2022).

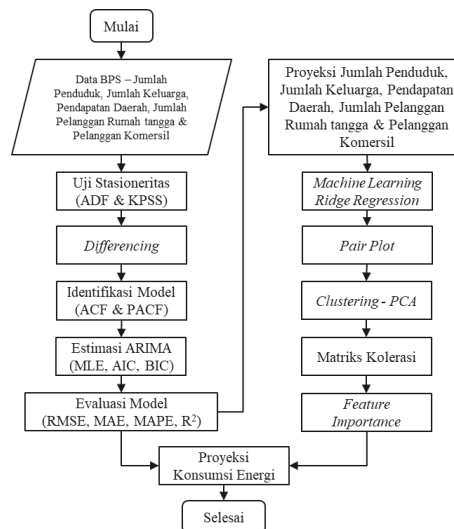
Berbagai pendekatan berbasis kecerdasan buatan dan machine learning telah diterapkan dalam peramalan energi. Namun, penggunaan model dengan kompleksitas tinggi seperti deep learning sering kali kurang sesuai untuk data berskala kecil hingga menengah karena berpotensi menimbulkan overfitting (Samimi, et al., 2022). dan menghasilkan model yang sulit diinterpretasikan (Navale, S., Mishra, N., & Borhade, S., 2025).. Dalam konteks perencanaan energi, interpretabilitas dan stabilitas model menjadi aspek yang sama pentingnya dengan akurasi (Srivastava, A. Et al., 2025)..

Penelitian ini bertujuan mengembangkan pendekatan pemodelan proyeksi kebutuhan energi yang sederhana namun andal dengan menggabungkan metode statistik klasik dan machine learning terregularisasi. Fokus utama penelitian ini adalah menyelaraskan dinamika temporal konsumsi energi dan hubungan struktural antar faktor sosio-ekonomi dalam satu kerangka pemodelan yang konsisten dan relevan secara kebijakan.

2. Data, Variabel, dan Metode Penelitian

Data yang digunakan dalam penelitian ini merupakan data dasar yang secara rutin dipublikasikan oleh Badan Pusat Statistik (BPS) pada tingkat nasional maupun regional, dengan wilayah studi difokuskan pada Pulau Tarakan. Pemilihan data ini bertujuan untuk memastikan ketersediaan, konsistensi, serta kemudahan replikasi model oleh mahasiswa dan peneliti pada berbagai konteks wilayah, khususnya pada sistem kelistrikan regional dan kepulauan.

Data yang dianalisis berupa deret waktu tahunan yang mencakup konsumsi energi listrik serta beberapa variabel sosio-ekonomi utama yang berperan sebagai faktor pendorong permintaan energi, yaitu jumlah rumah tangga, Produk Domestik Regional Bruto (PDRB) per kapita, dan jumlah pelanggan listrik. Variabel konsumsi energi listrik dinyatakan dalam bentuk rata-rata pemakaian energi harian, sedangkan variabel sosio-ekonomi merepresentasikan kondisi demografis dan aktivitas ekonomi wilayah studi. Seluruh variabel digunakan secara konsisten dalam dua tahap pemodelan, yaitu pemodelan statistik berbasis deret waktu dan pemodelan machine learning multivariat.



Gambar 2. Diagram Alir Penelitian

Penelitian diawali dengan pra-pemrosesan data yang mencakup pembersihan data, transformasi waktu, dan visualisasi awal untuk mengidentifikasi pola tren dan fluktuasi utama. Stasioneritas data diuji menggunakan Augmented Dickey–Fuller (ADF) dan Kwiatkowski–Phillips–Schmidt–Shin (KPSS), dengan penerapan differencing apabila diperlukan. Identifikasi dan estimasi model ARIMA dilakukan melalui analisis ACF–PACF dan Maximum Likelihood Estimation (MLE), sedangkan pemilihan model terbaik didasarkan pada signifikansi parameter serta kriteria AIC dan BIC. Validasi model dilakukan melalui analisis residual menggunakan uji Ljung–Box, dan kinerjanya dievaluasi terhadap metode baseline menggunakan metrik RMSE, MAE, MAPE, dan R^2 . Model ARIMA terpilih digunakan untuk membentuk skenario business as usual (Wang, X., & Meng, M., 2012) dan dibandingkan dengan proyeksi berbasis Ridge Regression untuk menghasilkan skenario dasar perencanaan energi jangka panjang (Li, J., et al., 2022).

3. Pemodelan Deret Waktu Menggunakan ARIMA

Model Auto Regressive Integrated Moving Average (ARIMA) digunakan untuk memodelkan dinamika temporal konsumsi energi dan variabel sosio-ekonomi secara univariat (Tan & Gopal, 2023). Uji stasioneritas dilakukan menggunakan Augmented Dickey–Fuller (ADF) dan KPSS. Data yang tidak stasioner diproses melalui differencing hingga memenuhi asumsi stasioneritas.

Identifikasi orde model dilakukan melalui analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF). Pemilihan model terbaik didasarkan pada nilai Akaike Information Criterion (AIC) dan Bayesian Information Criterion (BIC). Validitas model diuji melalui analisis residual

untuk memastikan tidak adanya autokorelasi tersisa dan terpenuhinya asumsi white noise. Model ARIMA yang terpilih digunakan sebagai skenario business as usual (BAU).

Tabel 1. Parameter Model ARIMA

Parameter	Model ARIMA	R2
Jumlah Rumah Tangga	(1.2.1)	0,99
Pendapatan Daerah	(1.2.1)	0,94
Jumlah Pelanggan Rumah Tangga	(1.1.1)	0,97
Jumlah Pelanggan Bisnis	(1.1.1)	0,94



Gambar 2. Data Aktual dan Hasil Fitting Model ARIMA

4. Pemodelan Multivariat Menggunakan Regresi Ridge


Untuk memodelkan hubungan simultan antara konsumsi energi dan faktor sosio-ekonomi, digunakan regresi ridge sebagai metode machine learning terregularisasi (Murel & Kavlakoglu, 2024). Regresi ridge dipilih untuk mengatasi permasalahan multikolinearitas yang umum terjadi pada variabel sosio-ekonomi.

$$\hat{\beta}_{ridge} = (X^T X + \lambda I)^{-1} X^T y \tag{1}$$

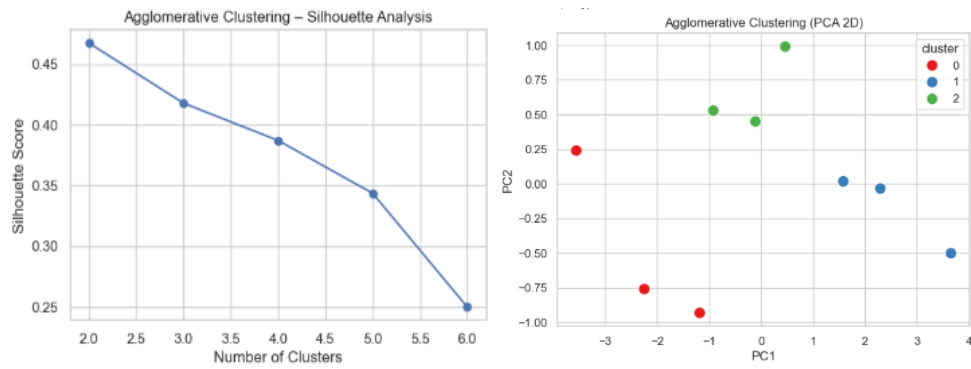
Estimator koefisien regresi ridge dinyatakan pada persamaan (1) dengan parameter λ merupakan hyperparameter regularisasi yang mengontrol tingkat penyusutan koefisien. Penambahan matriks λI menjamin matriks dapat diinvers dan menghasilkan estimasi yang lebih stabil.

Regresi ridge dikategorikan sebagai *supervised machine learning* karena menggunakan pasangan data input–output (X,y) , melatih parameter model melalui optimisasi fungsi loss, serta memiliki hyperparameter regularisasi λ yang ditentukan melalui proses validasi. Dalam praktik machine learning, regresi ridge diterapkan melalui pipeline yang mencakup normalisasi data, pelatihan model, penyesuaian hyperparameter, dan evaluasi performa menggunakan metrik kuantitatif seperti RMSE

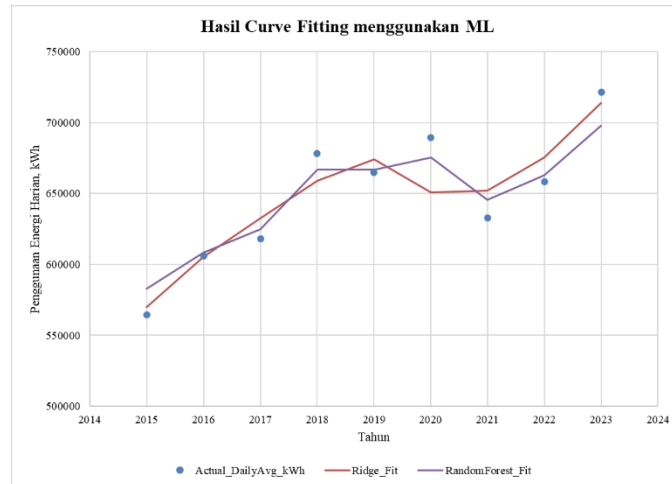
dan koefisien determinasi (R^2) untuk memastikan kemampuan generalisasi model. Sebagai pembandingan, digunakan model Random Forest untuk mengevaluasi pengaruh peningkatan kompleksitas algoritma terhadap performa prediksi.



Gambar 3. Korelasi Antar Variabel Sosio-Ekonomi



Gambar 4. Hasil Clustering dan Analisa PCA



Gambar 5. Perbandingan Kinerja Regresi Ridge dan Random Forest

5. Kerangka Pemodelan Hibrida

Pendekatan hibrida dikembangkan dengan menggunakan hasil proyeksi ARIMA sebagai input skenario BAU ke dalam model regresi ridge. Dengan pendekatan ini, ARIMA berfungsi menangkap dinamika temporal, sedangkan regresi ridge memetakan hubungan struktural antar variabel. Perbedaan hasil proyeksi digunakan sebagai indikasi ketidakpastian dan dasar penyusunan skenario konservatif dalam perencanaan energi.



Gambar 5. Perbandingan Proyeksi Konsumsi Energi ARIMA dan Regresi Ridge

6. Pembahasan

Hasil pemodelan menunjukkan bahwa model ARIMA mampu merepresentasikan tren historis konsumsi energi secara konsisten dan memenuhi seluruh asumsi statistik utama. Namun, pendekatan ini menghasilkan proyeksi yang relatif konservatif karena hanya bergantung pada pola historis.

Analisis multivariat menunjukkan adanya multikolinearitas tinggi antar variabel sosio-ekonomi. Dalam kondisi tersebut, regresi ridge menghasilkan estimasi yang stabil dan robust. Meskipun Random Forest menunjukkan nilai R^2 yang lebih tinggi, model ini dinilai kurang sesuai untuk perencanaan energi karena potensi overfitting dan rendahnya interpretabilitas.

Perbedaan hasil proyeksi antara ARIMA dan regresi ridge memberikan rentang ketidakpastian yang realistis dan relevan bagi perencanaan energi. Pendekatan hibrida memungkinkan pengambilan keputusan berbasis skenario tanpa meningkatkan kompleksitas model secara berlebihan.

7. Kesimpulan

Penelitian ini menunjukkan bahwa pendekatan sederhana yang mengombinasikan ARIMA dan regresi ridge mampu menghasilkan proyeksi kebutuhan energi yang andal dan relevan secara kebijakan. Pendekatan *simple yet reliable* ini sangat sesuai untuk perencanaan energi regional dengan keterbatasan data dan kebutuhan interpretabilitas yang tinggi. Penelitian selanjutnya dapat mengembangkan pendekatan ini dengan memasukkan skenario kebijakan atau variabel lingkungan tambahan.

Daftar Pustaka

- Auret, C., & Bekker, B. (2025). *A method for assessing the impact of historical weather dataset size when doing long-term electricity system planning*. Energy.
- Fahria, I., & Stevanus, H. (2022). *Time series model of forecast electricity energy consumption in Bangka Belitung Province*. IOP Conference Series: Earth and Environmental Science.
- Fu, Y., Lin, H., Ma, C., et al., & Wennersten, R. (2021). *Effects of uncertainties on the capacity and operation of an integrated energy system*. Sustainable Energy Technologies and Assessments.
- Li, J., Chen, H., Yang, J., et al. (2022). *Power consumption forecast based on ridge regression model*. In ACM International Conference Proceeding Series.
- Murel, J., & Kavlakoglu, E. (2024). Ridge regression. IBM Research. <https://www.ibm.com/id-id/think/topics/ridge-regression> (Diakses 18 November 2025)
- Nassreddine, G., El Abed, A., Nasserredine, M., & Al-Khatib, O. (2026). *AI-powered energy consumption prediction and forecasting*. In *Artificial Intelligence (AI) for IT Energy Efficiency and Green AI for Environment Sustainability*.
- Navale, S., Mishra, N., & Borhade, S. (2025). *Deep learning approaches for energy consumption forecasting: Analyzing stress factors and optimizing models for future demand*. Discover Applied Sciences.
- Samimi, R., Alyousef, A., Baranzini, D., & De Meer, H. (2022). *Boosting interpretability of non-readable deep learning forecasts: The case of buildings' energy consumptions prediction*. In *Proceedings of the 13th ACM International Conference on Future Energy Systems 2022*.
- Srivastava, A., Meena, P. K., Burande, C. G., et al., & Jhalani, A. (2025). *Empowering sustainable energy systems with AI: Opportunities, challenges, and strategic solutions*. Environmental Progress and Sustainable Energy.
- Tan, Y., & Gopal, V. (2023). *Introduction to time series analysis*. NUS Publishing.
- Wang, X., & Meng, M. (2012). *A hybrid neural network and ARIMA model for energy consumption forecasting*. Journal of Computers.