

PERBANDINGAN K-NEAREST NEIGHBORS (KNN) DAN SUPPORT VECTOR REGRESSION (SVR) UNTUK PREDIKSI KONSUMSI ENERGI LISTRIK

Retno Wahyusari^{1*}

Sekolah Tinggi Teknologi Ronggolawe, *Penulis Koresponden

e-mail: retnowahyusari@gmail.com*

ABSTRACT

Prediction of electrical energy consumption is a complex and important process in energy management. Especially in big cities where electrical energy consumption continues to increase along with population growth and technological developments. Unpredictable increases in energy consumption often cause an imbalance between electricity supply and demand. Therefore, electrical energy consumption prediction activities are needed to support electrical energy management activities. Accurate predictions help management optimize energy distribution, reduce operational costs, and support sustainable policies. Prediction models are included in the machine learning technique approach. Some algorithms that can be used are K-Nearest Neighbors (KNN) and Support Vector Regression (SVR). Both of these algorithms have the ability to handle non-linear and multidimensional data. This study uses the K-Nearest Neighbors (KNN) and Support Vector Regression (SVR) algorithms to predict electrical energy consumption on the Tetuan City Power Consumption dataset with the aim of measuring the performance of both models based on Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE). The dataset consists of 52,417 data, collected every 10 minutes for the period January-December 2017. This dataset has no missing values. The results show that the KNN model has a better performance with an RMSE of 0.14 and a MAPE of 0.23 (or 23%), while the SVR model has an RMSE of 0.16 and a MAPE of 0.31 (or 31%). This shows that KNN is more accurate and reliable in predicting electricity consumption than SVR. Further research can consider the use of other models that are able to handle more extreme data fluctuations or combine several algorithms to provide more accurate predictions. In addition, the use of datasets with additional variables or refinement of the data preprocessing process can improve model performance.

Keywords: electricity consumption prediction, KNN, MAPE, RMSE, SVR.

INTISARI

Prediksi konsumsi energi listrik merupakan proses yang kompleks dan penting dalam manajemen energi. Terutama di kota-kota besar yang konsumsi energi listrik terus meningkat seiring dengan pertumbuhan penduduk dan perkembangan teknologi. Peningkatan konsumsi energi yang tidak terprediksi seringkali menyebabkan ketidakseimbangan antara pasokan dan permintaan listrik. Maka perlu kegiatan prediksi konsumsi energi listrik guna mendukung kegiatan manajemen energi listrik. Prediksi yang akurat membantu manajemen dalam mengoptimalkan distribusi energi, pengurangan biaya operasional, dan mendukung kebijakan berkelanjutan. Model prediksi masuk ke dalam pendekatan teknik pembelajaran mesin. Beberapa algoritma yang dapat digunakan adalah *K-Nearest Neighbors* (KNN) dan *Support Vector Regression* (SVR). Kedua algoritma ini memiliki kemampuan dalam mengatasi data non-linier dan multidimensi. Penelitian ini menggunakan algoritma *K-Nearest Neighbors* (KNN) dan *Support Vector Regression* (SVR) untuk memprediksi konsumsi energi listrik pada dataset *Tetuan City Power Consumption* dengan tujuan mengukur performa kedua model berdasarkan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Dataset terdiri dari 52.417 data, dikumpulkan setiap 10 menit untuk periode Januari-Desember 2017. Dataset ini tidak memiliki nilai yang hilang. Hasil penelitian menunjukkan bahwa model KNN memiliki performa yang lebih baik dengan RMSE sebesar 0,14 dan MAPE sebesar 0,23 (atau 23%), sedangkan model SVR memiliki RMSE sebesar 0,16 dan MAPE sebesar 0,31 (atau 31%). Hal ini menunjukkan bahwa KNN lebih akurat dan andal dalam memprediksi konsumsi energi listrik dibandingkan SVR. Penelitian lebih lanjut dapat mempertimbangkan penggunaan model lain yang mampu menangani fluktuasi data yang lebih ekstrem atau menggabungkan beberapa algoritma agar dapat memberikan prediksi yang lebih akurat. Selain itu, penggunaan dataset dengan variabel tambahan atau penyempurnaan proses prapengolahan data dapat meningkatkan kinerja model.

Kata kunci: prediksi energi listrik, KNN, MAPE, RMSE, SVR.

1. PENDAHULUAN

Prediksi konsumsi energi listrik merupakan proses yang kompleks dan penting dalam manajemen energi. Proses prediksi sangat penting seiring dengan meningkatnya kebutuhan energi yang disebabkan oleh peningkatan pertumbuhan penduduk dan perkembangan teknologi (Hora dkk., 2021; Memarzadéh & Keynia, 2021). Prediksi yang akurat dan adaptif mengenai konsumsi energi listrik dapat membantu perencanaan distribusi, optimalisasi beban, pengurangan biaya operasional dan mendukung kebijakan berkelanjutan (Son & Shin, 2023; Tang dkk., 2024). Konsumsi energi listrik di kota-kota besar terus meningkat seiring dengan pertumbuhan penduduk dan perkembangan teknologi. Peningkatan konsumsi energi yang tidak terprediksi seringkali menyebabkan ketidakseimbangan antara pasokan dan permintaan listrik. Oleh karena itu, banyak penelitian melakukan prediksi konsumsi energi listrik (Antolak & Pułka, 2024; da Silva & Meneses, 2023; Hasan dkk., 2024; Olu-Ajayi dkk., 2023). Penelitian menggunakan beberapa algoritma dalam memprediksi energi listrik. Model prediksi masuk ke dalam pendekatan teknik pembelajaran mesin. Beberapa algoritma yang dapat digunakan adalah *K-Nearest Neighbors* (KNN) dan *Support Vector Regression* (SVR). Kedua algoritma ini memiliki kemampuan dalam mengatasi data non-linier dan multidimensi.

Algoritma *K-Nearest Neighbors* (KNN) adalah prosedur pembelajaran yang dipicu oleh kueri namun bersifat improvisasi, yang dilakukan hanya ketika data uji diprediksi yang menetapkan nilai K yang sesuai dan mencari K terdekat tetangga dari seluruh ruang sampel pelatihan. Artinya Klasifikasi KNN merupakan salah satu algoritma *lazy learning* (Zhang & Li, 2023). KNN sering digunakan karena kesederhanaan serta kemampuan memodelkan hubungan dengan baik. Di sisi lain, *Support Vector Regression* (SVR), mampu memodelkan data yang memiliki hubungan non-linier melalui kernel trick (Smola & Scholkopf, 2004). SVR memiliki kemampuan untuk menemukan *hyperplane* optimal yang meminimalkan kesalahan prediksi dengan menjaga margin terbesar antara titik data dan *hyperplane* (Karamizadeh dkk., 2014; Yasmin dkk., 2021). Keunggulan SVR terletak pada kemampuannya untuk mengatasi *overfitting*, terutama pada data yang memiliki distribusi yang tidak seragam, serta kemampuannya untuk bekerja baik pada dataset berukuran kecil hingga menengah dengan performa yang stabil (Drucker dkk., 1997; Muthiah dkk., 2021).

Beberapa penelitian yang menggunakan KNN untuk prediksi antara lain prediksi harga rumah, penelitian membandingkan KNN dan Naïve Bayes, hasil menunjukkan bahwa model pembelajaran *lazy learning* memiliki kinerja yang lebih unggul dalam nilai *accuracy score* adalah 0,5714. Sedangkan *accuracy score* *Naïve Bayes* adalah 0,4 (Ariyani dkk., 2022). Penelitian prediksi kelulusan menggunakan KNN mendapatkan hasil nilai k=5, tingkat akurasi sebesar 80.00% yang ditetapkan sebagai k-Optimal (Gadi Ana Amas dkk., 2024). Penelitian selanjutnya prediksi status gizi. Hasil dari sistem status gizi berdasarkan BB/U (Berat Badan menurut Umur) yaitu gizi buruk, gizi kurang, gizi baik, gizi lebih. Berdasarkan hasil pengujian dengan *confusion matrix*, akurasi tingkat keberhasilan penentuan status gizi balita dengan metode KNN yang dihasilkan oleh sistem ini mencapai 88,06% (Yunus & Pratiwi, 2023).


Penelitian prediksi menggunakan metode SVR dilakukan oleh Siti Saadah dkk (2021) memprediksi harga kelapa sawit menggunakan SVR mendapatkan hasil prediksi harga minyak kelapa sawit di Indonesia, akurasi prediksi pada rentang 98%. Penelitian dilakukan Muhammad Furqan Rasyid dkk (2022) data yang digunakan *Sub Varian Omicron*. Berdasarkan Pengujian yang telah dilakukan menggunakan analisis regresi, di peroleh akurasi sebesar 67.4 %. Prediksi kurs mata uang asing menggunakan SVR menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) yaitu 0.817317 dengan menggunakan komposisi data 90 : 10 (Wahyudi dkk., 2024). Berdasarkan uraian di atas maka penelitian prediksi konsumsi energi listrik menggunakan data Tetuan city *power consumption* (Salam & Hibaoui, 2018), proses prediksi menggunakan metode KNN dan SVR. Pemanfaatan dataset Tetuan city *power consumption* sebab dataset merupakan data publik yang sudah banyak digunakan dalam penelitian, dataset mewakili kondisi nyata konsumsi energi listrik pada Tetuan, Maroko, serta memiliki variasi data. Dataset terdiri dari 52.417 data, dikumpulkan setiap 10 menit untuk periode Januari-Desember 2017. Dataset ini tidak memiliki nilai yang hilang.

Penelitian ini bertujuan untuk membandingkan performa metode *K-Nearest Neighbors* (KNN) dan *Support Vector Regression* (SVR) dalam meramalkan konsumsi energi listrik di Kota Tetuan. Perbandingan kinerja kedua metode ini akan dilakukan dengan menggunakan metrik evaluasi *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Dataset yang digunakan adalah *Tetuan City Power Consumption*. Tujuan akhir dari penelitian ini adalah untuk mengidentifikasi metode mana yang lebih baik dalam memprediksi konsumsi energi listrik berdasarkan dataset yang ada.

2. ALGORITMA PENELITIAN

Kegiatan penelitian dilakukan dalam 4 (empat) tahapan yaitu kajian pustaka, algoritma penelitian, tujuan, dan

pengukuran. Pada algoritma penelitian terdapat kegiatan pengumpulan data, pengolahan data awal, prediksi menggunakan KNN dan SVR. Tujuannya mampu memprediksi konsumsi energi listrik, pengukuran kinerja menggunakan RMSE dan MAPE. Gambar 1 merupakan tahapan dalam penelitian.



Gambar 1. Alur Penelitian

2.1 Kajian Pustaka

Kajian pustaka merupakan proses sistematis yang melibatkan pengumpulan, evaluasi, analisis, dan sintesis informasi dari berbagai sumber yang relevan dengan topik penelitian. Kegiatan ini bertujuan untuk membangun landasan teoretis yang kuat, mengidentifikasi celah pengetahuan dalam literatur yang ada, serta memberikan arah yang jelas bagi penelitian yang akan dilakukan.

2.2 Metode Penelitian

Algoritma penelitian terdiri dari 3 (tiga) tahapan yaitu pengumpulan data, pengolahan data awal, dan prediksi. Tahap pengumpulan data dilakukan sebagai langkah awal dari suatu penelitian. Proses pengumpulan data dengan menggunduh dataset *Energy Consumption Prediction* yang ada di Kaggle. Pengolahan data awal melakukan kegiatan menghapus data yang tidak dibutuhkan dalam kegiatan prediksi dan melakukan proses normalisasi Min Max. Normalisasi Min Max merupakan proses penskalaan data ke dalam rentang tertentu, biasanya pada rentang 0 dan 1(Muhammad Ali, 2022). Formula normalisasi Min-Max tersaji pada formula nomor 1.

Proses selanjutnya adalah melakukan prediksi menggunakan algoritma KNN dan SVR. Algoritma KNN menggunakan klasifikasi ketetanggaan sebagai nilai prediksi dari sampel uji yang baru. Formula algoritma KNN tesaji pada formula 2.

$$euc = \sqrt{\sum_{k=1}^d (a_k - b_k)^2} \quad \dots \dots \dots \quad (2)$$

keterangan:

a : data latih

b : data uji

k : variabel data

d : dimensi data
 Cara kerja algoritma KNN diperlukan penentuan data latih, data uji, dan nilai k. Selanjutnya, data latih diurutkan berdasarkan hitungan jarak terdekat antara data uji dan data latih. Dan terakhir, diambil rata-rata data latih terkecil yang jumlahnya setara dengan k.

Algoritma SVR memiliki prinsip mencari *hyperplane* (garis dalam dimensi dua, bidang dalam dimensi tiga, dll.) yang bertujuan meminimalkan kesalahan prediksi sampai margin di sekitar *hyperplane*.

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (3)$$

$$f(x) = \sum_{i=1}^l \beta K(x_i, x_j) + b \quad \dots \dots \dots \quad (4)$$

Dimana β adalah jarak antara α_i dan α_i^* , sedangkan $K(x_i, x_j)$ merupakan fungsi kernel.

2.3 Tujuan

Tahap tujuan adalah menghasilkan prediksi konsumsi energi listrik berdasarkan algoritma KNN dan SVR. Metode penelitian melakukan proses pengumpulan data hingga prediksi konsumsi enegi listrik. Hasil prediksi kemudian diukur tingkat kinerjanya pada tahap pengukuran.

2.4 Pengukuran

Pada tahap akhir, model yang telah dikembangkan akan dievaluasi dan divalidasi secara komprehensif. Evaluasi ini bertujuan untuk mengukur kinerja model secara kuantitatif dengan menghitung *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). RMSE mengukur seberapa jauh nilai prediksi dari nilai asli. Formula 4 merupakan RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \dots \dots \dots \quad (5)$$

MAPE mengekspresikan kesalahan dalam bentuk persentase. Perhitungan nilai MAPE diperoleh dari rata-rata absolut dari presentase *error*. Formula 6 merupakan formula untuk menghitung nilai MAPE.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad \dots \dots \dots \quad (6)$$

Dimana y_i adalah nilai aktual pada periode i , \hat{y}_i adalah nilai prediksi pada periode i . n merupakan jumlah data. Berdasarkan Colin David Lewis (1982), nilai MAPE dapat dikategorikan ke dalam 4 kategori yaitu:

Tabel 1. Kategori Nilai MAPE

MAPE (%)	Kategori
<10	Sangat Akurat
10-20	Baik
20-50	Layak/ Wajar
>50	Tidak Akurat

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Penelitian ini menggunakan dataset yang terdiri dari 52416 data, mencakup berbagai variabel seperti *DateTime*, *Temperature*, *Humidity*, *Wind Speed*, *general diffuse flows*, *diffuse flows*, *Zone 1 Power Consumption*, *Zone 2 Power Consumption*, *Zone 3 Power Consumption*. Tabel 2 memberikan gambaran mengenai data sebelum dilakukan proses pengolahan data awal.

Tabel 2. Dataset Tetuan city *power consumption*.

Table 2: Dataset - Total city power consumption									
Date/Time	Temperature	Humidity	Wind Speed	Zone 1 Power Consumption	Zone 2 Power Consumption	Zone 3 Power Consumption	
01/01/2017 00:00	6.559	73.8	0.083	34055.6962	16128.87538	20240.96386	
01/01/2017 00:10	6.414	74.5	0.083	29814.68354	19375.07599	20131.08434	
01/01/2017 00:20	6.313	74.5	0.08	29128.10127	19006.68693	19668.43373	
...	
12/30/2017 23:50	6.58	74.1	0.081	28349.80989	24055.23167	13345.4982	

3.2 Pengolahan Data Awal

Data *DateTime*, *Zone 2 Power Consumption*, dan *Zone 3 Power Consumption* pada proses pengolahan data awal dihilangkan, sebab data tersebut tidak digunakan dalam proses prediksi. Data *DateTime* hanya merepresentasikan waktu dalam bentuk teks atau string hanya sebagai metadata. Dalam bentuk asli tidak memberikan informasi kuantitatif langsung untuk proses prediksi. Selain itu, pada penelitian tidak mempertimbangkan melatih model dengan fitur berbasis waktu yang eksplisit (seperti hari kerja atau tidak dan musim), sehingga dapat menyederhanakan model prediksi. *Zone 2 Power Consumption*, dan *Zone 3 Power Consumption* dihapus, sebab penelitian hanya fokus pada konsumsi pada *Zone 1 Power Consumption*. Langkah selanjutnya dilakukan proses normalisasi data menggunakan Min-Max, hasil normalisasi terlihat pada Tabel 3.


Tabel 3. Data Hasil Normalisasi *Min-Max*

Temperature	Humidity	Wind Speed	General Diffuse Flows	Diffuse Flows	Zone 1 Power Consumption
0.09009058	0.748382459	0.005129799	4.04E-05	0.000115386	0.526251232
0.086146397	0.75676971	0.005129799	5.67E-05	7.91E-05	0.415544975
0.08339907	0.75676971	0.004663454	4.99E-05	9.51E-05	0.397622616
...
0.090661807	0.751976995	0.004818903	4.99E-05	0.000106839	0.377306306

Dataset perlu dilakukan normalisasi sebab pada datset memiliki data bervariasi, seperti *Temperature* dan *Humidity* memiliki nilai dalam puluhan sedangkan *Zone 1 Power Consumption* memiliki nilai yang jauh lebih besar. Sehingga dapat mempegaruhi proses prediksi. Fitur dengan nilai besar (misalnya, konsumsi daya) mendominasi perhitungan gradien, dan Fitur dengan nilai kecil (misalnya, suhu) menjadi kurang penting meskipun relevan. Normalisasi Min-Max berkonstibusi dalam menyeimbangkan semua fitur, sebab fitur berada dalam rentang 0 sampai 1.


3.3 Prediksi

Berdasarkan Gambar 2, terlihat bahwa prediksi model KNN (oranye) cenderung mengikuti pola data aktual (biru) dengan cukup baik, tetapi ada beberapa bagian di mana nilai aktual berbeda cukup signifikan dari prediksi. Hal ini menunjukkan bahwa KNN berhasil menangkap pola umum dari data, namun memiliki keterbatasan dalam menyesuaikan diri pada beberapa fluktuasi yang lebih ekstrem.



Gambar 2. Hasil Prediksi KNN


Gambar 3 memperlihatkan perbandingan antara nilai sebenarnya (biru) dan nilai yang diprediksi (orange) oleh model. Pada gambar terlihat hasil prediksi semuanya jauh dari nilai aktual, hal ini menunjukkan bahwa metode SVR kurang kuat dalam memprediksi konsumsi energi listrik.



Gambar 3. Hasil Prediksi SVR

3.4 Pengukuran

Model KNN memiliki RMSE lebih rendah (0,14) dibandingkan SVR (0,16), yang menunjukkan bahwa model KNN lebih akurat dalam memprediksi konsumsi energi daripada SVR. KNN memiliki MAPE yang lebih rendah dibandingkan SVR, yang berarti KNN lebih andal dalam menjaga akurasi persentase prediksi terhadap nilai aktual. MAPE sebesar 0,23 (atau 23%) untuk KNN berarti, secara rata-rata, prediksi KNN menyimpang sekitar 0,23 (atau 23%) dari nilai aktual. Sebaliknya, SVR memiliki MAPE sebesar 0,31 (atau 31%), yang lebih besar, menandakan bahwa SVR cenderung memberikan prediksi yang memiliki kesalahan persentase lebih tinggi. Gambar 4 menunjukkan perbandingan hasil pengukuran berdasarkan nilai RMSE dan MAPE. Jika dilihat berdasarkan tabel kategori nilai MAPE, maka hasil prediksi masuk kedalam kategori layak atau wajar.



Gambar 4. Unjuk Kerja Algoritma KNN dan SVR

4. KESIMPULAN

Penelitian membandingkan kinerja algoritma *K-Nearest Neighbors* (KNN) dan *Support Vector Regression* (SVR) dalam memprediksi konsumsi energi listrik. Dengan menggunakan data sebanyak 52416 data, kinerja diukur berdasarkan matrik evaluasi RMSE dan MAPE. Dari hasil analisis menunjukkan algoritma KNN lebih unggul dibanding algoritma SVR. KNN berhasil mencapai nilai RMSE 0,14 dan SVR mendapatkan nilai 0,16, hal ini berarti KNN memiliki nilai RMSE lebih rendah dibandingkan SVR. Prediksi KNN menyimpang sekitar 0,23 (atau 23%) dari nilai actual, sebaliknya, SVR memiliki MAPE sebesar 0,31 (atau 31%). KNN memiliki MAPE yang lebih rendah dibandingkan SVR, yang berarti KNN lebih andal dalam memprediksi. Kedua algoritma jika dikategorikan berdasarkan tabel kategori nilai MAPE masuk ke dalam tingkat layak atau wajar.

DAFTAR PUSTAKA

- Antolak, E., & Pułka, A. (2024). Power Consumption Prediction in Real-Time Multitasking Systems. *Electronics (Switzerland)*, 13(7). <https://doi.org/10.3390/electronics13071347>
- Ariyani, V., Putri, P., Prasetyo, A. B., & Eridani, D. (2022). Perbandingan Kinerja Algoritme Naïve Bayes Dan K-Nearest Neighbor (Knn) Untuk Prediksi Harga Rumah. *Jurnal Ilmiah Teknik Elektro*, 24(2), 162–171. <https://ejournal.undip.ac.id/index.php/transmisi>
- da Silva, D. G., & Meneses, A. A. de M. (2023). Comparing Long Short-Term Memory (LSTM) and bidirectional

- LSTM deep neural networks for power consumption prediction. *Energy Reports*, 10(October), 3315–3334. <https://doi.org/10.1016/j.egyr.2023.09.175>
- Drucker, H., Surges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in Neural Information Processing Systems*, 1, 155–161.
- Gadi Ana Amas, A., Kopong Pati, G., Ema Ose Sanga, F., Informatika, T., & Stella Maris Sumba, S. (2024). JESCE (Journal of Electrical and System Control Engineering) Penerapan K-Optimal Pada Algoritma KNN Untuk Prediksi Kelulusan Tepat Waktu Mahasiswa Program Studi Teknik Informatika Application of K-Optimal in the KNN Algorithm to Predict Timely Graduation . *Jesce*, 7(2), 92–97. <https://doi.org/10.31289/jesce.v6i2.10536>
- Hasan, M. Y., Kadhim, D. J., & Humaidi, A. J. (2024). Prediction of electricity-consumption and residential bills based on artificial neural network. *International Review of Applied Sciences and Engineering*. <https://doi.org/10.1556/1848.2024.00856>
- Hora, S. K., Poongodan, R., de Prado, R. P., Wozniak, M., & Divakarachari, P. B. (2021). Long short-term memory network-based metaheuristic for effective electric energy consumption prediction. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/app112311263>
- Karamizadeh, S., Abdullah, S. M., Halimi, M., Shayan, J., & Rajabi, M. J. (2014). Advantage and drawback of support vector machine functionality. *I4CT 2014 - 1st International Conference on Computer, Communications, and Control Technology, Proceedings*, I4ct, 63–65. <https://doi.org/10.1109/I4CT.2014.6914146>
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. Butterworth Scientific. <https://books.google.co.id/books?id=t8W4AAAAIAAJ>
- Memarzadeh, G., & Keynia, F. (2021). Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm. *Electric Power Systems Research*, 192(July 2020), 106995. <https://doi.org/10.1016/j.epsr.2020.106995>
- Muhammad Ali, P. J. (2022). Investigating the Impact of Min-Max Data Normalization on the Regression Performance of K-Nearest Neighbor with Different Similarity Measurements. *Aro-the Scientific Journal of Koya University*, 10(1), 85–91. <https://doi.org/10.14500/aro.10955>
- Muthiah, H., Sa, U., & Efendi, A. (2021). Support Vector Regression (SVR) Model for Seasonal Time Series Data. *Proceedings of the Second Asia Pacific International Conference on Industrial Engineering and Operations Management, September 14-16, 2021*, 3191–3200.
- Olu-Ajaiy, R., Alaka, H., Owolabi, H., Akanbi, L., & Ganiyu, S. (2023). Data-Driven Tools for Building Energy Consumption Prediction: A Review. *Energies*, 16(6), 1–20. <https://doi.org/10.3390/en16062574>
- Rasyid, M. F., Djafar, I., & Mahersatillah, A. A. (2022). Prediksi penyebaran Sub Varian omicron di Indonesia menggunakan Machine Learning. *Prosiding Seminar Ilmiah Sistem Informasi Dan Teknologi Informasi, XI(1)*, 1–7.
- Saadah, S., Z, F. Z., & Z, H. H. (2021). Support Vector Regression (SVR) Dalam Memprediksi Harga Minyak Kelapa Sawit di Indonesia dan Nilai Tukar Mata Uang EUR/USD. *Journal of Computer Science and Informatics Engineering (J-Cosine)*, 5(1), 85–92. <https://doi.org/10.29303/jcosine.v5i1.403>
- Salam, A., & Hibaoui, A. El. (2018). Comparison of Machine Learning Algorithms for the Power Consumption Prediction - Case Study of Tetouan city –. *International Renewable and Sustainable Energy Conference (IRSEC)*, 1–5. <https://doi.org/10.1109/IRSEC.2018.8703007>
- Smola, A. J., & Scholkopf, B. (2004). Identification of TRACs (T3 receptor-associating cofactors), a family of cofactors that associate with, and modulate the activity of, nuclear hormone receptors. *Molecular Endocrinology*, 10(7), 813–825. <https://doi.org/10.1210/me.10.7.813>
- Son, N., & Shin, Y. (2023). Short- and Medium-Term Electricity Consumption Forecasting Using Prophet and GRU. *Sustainability (Switzerland)*, 15(22). <https://doi.org/10.3390/su152215860>
- Tang, J., Saga, R., Cai, H., Ma, Z., & Yu, S. (2024). Advanced Integration of Forecasting Models for Sustainable Load Prediction in Large-Scale Power Systems. *Sustainability (Switzerland)*, 16(4). <https://doi.org/10.3390/su16041710>
- Wahyudi, A., Setiawan, W., Dwi, Y., & Negara, P. (2024). *PREDIKSI KURS MATA UANG RIYAL KE RUPIAH MENGGUNAKAN METODE SUPPORT VECTOR REGRESSION (SVR)*. 10(2).
- Yasmin, N. S. A., Wahab, N. A., Ismail, F. S., Musa, M. J., Halim, M. H. A., & Anuar, A. N. (2021). Support vector regression modelling of an aerobic granular sludge in sequential batch reactor. *Membranes*, 11(8). <https://doi.org/10.3390/membranes11080554>
- Yunus, M., & Pratiwi, N. K. A. (2023). Prediksi Status Gizi Balita Dengan Algoritma K-Nearest Neighbor (KNN) di Puskemas Cakranegara. *JTIM : Jurnal Teknologi Informasi dan Multimedia*, 4(4), 221–231. <https://doi.org/10.35746/jtim.v4i4.328>
- Zhang, S., & Li, J. (2023). KNN Classification With One-Step Computation. *IEEE Transactions on Knowledge and Data Engineering*, 35(3), 2711–2723. <https://doi.org/10.1109/TKDE.2021.3119140>