

Analisis Perbandingan Kinerja Jaringan Saraf Tiruan (JST) yang Dioptimalkan Metaheuristik dan Regresi Vektor Pendukung untuk Prediksi Konsumsi Energi Listrik

Giovanni Dimas Preanta¹

^{1,2}Universitas 17 Agustus 1945 Surabaya

Jl. Semolowaru No.45, Menur Pumpungan, Kec. Sukolilo, Surabaya, Jawa Timur 60118, Indonesia

e-mail: gprenata@untag-sby.ac.id

Abstrak— Penelitian ini menganalisis kinerja prediksi konsumsi energi listrik dengan membandingkan model Artificial Neural Network (ANN) berbasis optimasi metaheuristik pada penelitian sebelumnya dengan model Support Vector Regression (SVR) yang diimplementasikan secara mandiri. Model SVR menggunakan pendekatan regresi linear ϵ -insensitive dengan regularisasi, serta dilakukan normalisasi fitur untuk menjaga stabilitas pelatihan. Hasil eksperimen menunjukkan bahwa SVR mampu menghasilkan akurasi prediksi yang sangat tinggi pada data latih dengan akurasi relatif per-sampel 96,74%–99,90% dan rata-rata akurasi latih 99,09%, serta mempertahankan generalisasi pada data uji dengan akurasi 92,56%. Dibandingkan ANN dengan optimasi metaheuristik (GA/PSO) yang umumnya memerlukan proses pelatihan lebih kompleks dan bergantung pada inisialisasi, SVR menawarkan nilai tambah berupa pelatihan yang lebih stabil, deterministik, dan mudah direproduksi dengan kompleksitas model yang lebih rendah. Temuan ini menegaskan bahwa SVR dapat menjadi alternatif yang efektif dan efisien untuk prediksi konsumsi energi listrik sekaligus pembanding yang kuat terhadap pendekatan ANN metaheuristik.

Kata kunci: *Support Vector Regression, Prediksi Konsumsi Energi Listrik, Metaheuristic-Optimized ANN, Machine Learning, ϵ -insensitive Loss*

Abstract—This study analyzes the performance of electricity consumption prediction by comparing a metaheuristic optimization-based Artificial Neural Network (ANN) model from previous studies with a standalone Support Vector Regression (SVR) model. The SVR model uses an ϵ -insensitive linear regression approach with regularization, and feature normalization is performed to maintain training stability. Experimental results show that SVR is capable of producing very high prediction accuracy on training data with a relative accuracy per sample of 96.74%–99.90% and an average training accuracy of 99.09%, while maintaining generalization on test data with an accuracy of 92.56%. Compared to ANN with metaheuristic optimization (GA/PSO), which generally requires a more complex training process and relies on initialization, SVR offers the added value of more stable, deterministic, and easily reproducible training with lower model complexity. These findings confirm that SVR can be an effective and efficient alternative for electricity consumption prediction as well as a strong comparison to the ANN metaheuristic approach.

Keywords: *Support Vector Regression, Electrical Energy Consumption Prediction, Metaheuristic-Optimized ANN, Machine Learning, ϵ -insensitive Loss*

I. PENDAHULUAN

Konsumsi energi listrik merupakan salah satu indikator krusial dalam perencanaan dan pengelolaan sistem tenaga listrik, terutama di negara berkembang seperti Indonesia yang mengalami peningkatan beban secara signifikan akibat pertumbuhan penduduk, ekspansi sektor industri, dan aktivitas ekonomi yang terus meningkat. Ketidakakuratan dalam memprediksi konsumsi energi listrik dapat menyebabkan ketidakseimbangan antara sisi pembangkitan dan beban, yang berdampak langsung pada inefisiensi operasional sistem, peningkatan biaya produksi energi,

serta menurunnya tingkat keandalan sistem tenaga listrik. Oleh karena itu, dibutuhkan suatu metode prediksi yang tidak hanya mampu menghasilkan kesalahan prediksi yang rendah pada data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru agar dapat digunakan sebagai dasar pengambilan keputusan operasional dan perencanaan jangka menengah hingga panjang [1].

Berbagai pendekatan telah digunakan untuk memprediksi konsumsi energi listrik, mulai dari metode statistik konvensional hingga pendekatan berbasis machine learning.

Salah satu metode yang banyak digunakan adalah *Artificial Neural Network* (ANN), karena kemampuannya dalam memodelkan hubungan nonlinier antara variabel input dan output. Penelitian sebelumnya menunjukkan bahwa ANN mampu menghasilkan tingkat kesalahan prediksi yang relatif rendah dalam kasus prediksi beban dan konsumsi energi listrik [2], [3]. Namun demikian, kinerja ANN sangat dipengaruhi oleh proses pelatihan bobot, inisialisasi awal, serta parameter pembelajaran, sehingga sering kali menghadapi permasalahan konvergensi lambat dan potensi terjebak pada *local minimum* [4], [5].

Untuk mengatasi keterbatasan tersebut, berbagai penelitian telah mengombinasikan ANN dengan metode optimasi metaheuristik, seperti *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO), guna meningkatkan kualitas bobot jaringan dan memperbaiki akurasi prediksi. Hasil penelitian menunjukkan bahwa ANN yang dioptimasi menggunakan metaheuristik mampu menghasilkan performa yang lebih stabil dan akurat dibandingkan ANN dengan pelatihan *backpropagation* konvensional [4], [5]. Studi perbandingan juga menunjukkan bahwa pendekatan ANN berbasis optimasi cenderung lebih unggul dibandingkan beberapa metode *machine learning* lain dalam konteks data konsumsi energi listrik [6].

Penelitian terbaru juga menunjukkan bahwa kombinasi *deep feedforward neural network* (DFFNN) dengan optimasi metaheuristik seperti *Genetic Algorithm* (GA) dan *Grey Wolf Optimizer* (GWO) mampu meningkatkan efisiensi konvergensi serta kestabilan prediksi konsumsi energi listrik pada skenario data temporal. Selain itu, penggunaan pendekatan *sliding window cross-validation* (SWCV) memberikan evaluasi generalisasi yang lebih realistis terhadap data masa depan dibandingkan metode *train-test split* konvensional. Hasil penelitian tersebut menunjukkan bahwa DFFNN-GWO unggul dari sisi efisiensi iterasi, sedangkan *Long Short-Term Memory* (LSTM) memiliki kestabilan prediksi temporal yang baik pada data deret waktu energi listrik [7].

Penelitian lain [8] yang secara khusus mengevaluasi performa ANN dengan tiga strategi pelatihan, yaitu *Backpropagation*, *Genetic Algorithm*, dan *Particle Swarm Optimization*, untuk prediksi konsumsi energi listrik. Hasil penelitian tersebut menunjukkan bahwa ANN-GA memberikan kinerja terbaik dengan nilai *Mean Absolute Error* (MAE) yang rendah dan stabilitas generalisasi yang baik dibandingkan metode lainnya. Meskipun demikian, penelitian tersebut masih terbatas pada pendekatan ANN, sehingga membuka peluang untuk mengeksplorasi metode alternatif yang memiliki karakteristik generalisasi yang lebih kuat dan kompleksitas model yang lebih terkendali.

Salah satu metode *machine learning* yang dikenal memiliki kemampuan generalisasi yang baik adalah *Support Vector Regression* (SVR). SVR merupakan pengembangan dari *Support Vector Machine* (SVM) yang dirancang untuk permasalahan regresi dengan prinsip *structural risk minimization*, sehingga mampu menghindari *overfitting* meskipun jumlah data relatif terbatas. Beberapa penelitian telah menunjukkan bahwa SVR mampu menghasilkan akurasi prediksi yang kompetitif dalam kasus prediksi konsumsi energi listrik dan beban listrik, serta lebih stabil terhadap variasi data dibandingkan metode ANN konvensional [9], [6], [10].

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk melakukan analisis perbandingan kinerja antara ANN yang dioptimasi menggunakan metode metaheuristik dan

metode SVR dalam memprediksi konsumsi energi listrik. Penelitian ini merupakan kelanjutan langsung dari penelitian sebelumnya [9], dengan fokus pada evaluasi kemampuan SVR sebagai alternatif *machine learning* yang lebih sederhana namun memiliki performa prediksi yang kompetitif. Dengan membandingkan hasil prediksi, tingkat kesalahan, dan karakteristik konvergensi model, penelitian ini diharapkan dapat memberikan kontribusi dalam pemilihan metode prediksi konsumsi energi listrik yang lebih akurat, efisien, dan aplikatif untuk perencanaan sistem tenaga listrik di Indonesia.

II. STUDI PUSTAKA

Support Vector Regression (SVR) merupakan pengembangan dari metode *Support Vector Machine* (SVM) yang ditujukan untuk menyelesaikan permasalahan regresi. Berbeda dengan pendekatan regresi klasik yang meminimalkan kesalahan prediksi secara langsung, SVR membangun model regresi berdasarkan prinsip *structural risk minimization*, yaitu dengan mengendalikan kompleksitas model sekaligus meminimalkan kesalahan prediksi. Pendekatan ini memungkinkan SVR memiliki kemampuan generalisasi yang baik, terutama pada data dengan jumlah terbatas atau memiliki variasi yang tinggi.

Secara umum, SVR bertujuan untuk mencari sebuah fungsi regresi linier yang dinyatakan sebagai:

$$f(x) = w \cdot x + b \quad (1)$$

di mana w merupakan vektor bobot, x adalah vektor input, dan b adalah bias. Fungsi ini diharapkan mampu merepresentasikan hubungan antara variabel input dan output dengan tingkat kesalahan yang masih dapat ditoleransi.

Ciri utama SVR adalah penggunaan fungsi kerugian ϵ -insensitive loss, yang didefinisikan sebagai:

$$\begin{aligned} L_{\epsilon}(y, f(x)) &= 0, \text{ jika } |y - f(x)| \leq \epsilon \\ L_{\epsilon}(y, f(x)) &= |y - f(x)| - \epsilon, \text{ jika } |y - f(x)| > \epsilon \end{aligned} \quad (2)$$

dengan y sebagai nilai target aktual dan ϵ sebagai batas toleransi kesalahan. Melalui fungsi ini, kesalahan prediksi yang berada di dalam rentang ϵ dianggap tidak signifikan dan tidak dikenakan penalti, sehingga model menjadi lebih robust terhadap noise dan fluktuasi kecil pada data.

Permasalahan optimasi pada SVR diformulasikan dengan tujuan meminimalkan fungsi objektif berikut:

$$\min (1/2 ||w||^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)) \quad (4)$$

dengan kendala:

$$y_i - (w \cdot x_i + b) \leq \epsilon + \xi_i \quad (5)$$

$$(w \cdot x_i + b) - y_i \leq \epsilon + \xi_i^* \quad (6)$$

$$\xi_i, \xi_i^* \geq 0 \quad (7)$$

Pada persamaan tersebut, ξ_i dan ξ_i^* variabel slack yang merepresentasikan kesalahan prediksi di luar batas ϵ , sedangkan parameter C berfungsi sebagai faktor regularisasi yang mengatur kompromi antara kompleksitas


model dan besarnya kesalahan yang diizinkan. Nilai C yang besar cenderung menghasilkan model yang lebih fleksibel namun berisiko *overfitting*, sedangkan nilai C yang kecil menghasilkan model yang lebih sederhana dan stabil.

Dalam implementasi praktis, parameter w dan b dapat diperoleh melalui proses optimasi iteratif, misalnya menggunakan pendekatan *stochastic gradient descent* pada fungsi kerugian ϵ -insensitive. Proses ini dilakukan hingga fungsi objektif mencapai kondisi konvergen, yang ditandai dengan perubahan kesalahan prediksi yang sangat kecil atau telah mencapai ambang batas tertentu.

Dengan karakteristik tersebut, SVR menjadi metode regresi yang efektif untuk memodelkan hubungan input-output secara stabil dan presisi. Kombinasi antara regularisasi eksplisit dan fungsi kerugian ϵ -insensitive menjadikan SVR sangat sesuai untuk prediksi konsumsi energi listrik, di mana data sering kali bersifat fluktuatif dan jumlah sampel terbatas, namun tetap menuntut tingkat akurasi yang tinggi.

III. METODE

Metode SVR merupakan pendekatan *Support Vector Regression (SVR) linear dengan ϵ -insensitive loss function* yang diimplementasikan secara mandiri tanpa menggunakan pustaka eksternal. Model ini dirancang sebagai pembandingan langsung terhadap model *Artificial Neural Network (ANN)* yang digunakan pada penelitian sebelumnya, dengan tetap mempertahankan struktur data, jumlah fitur, serta skema pengujian yang sama agar perbandingan kinerja dapat dilakukan secara adil dan konsisten.



Gambar 1. Diagram alir metode SVR

Data latih yang digunakan pada SVR terdiri dari enam variabel input (X_0 - X_5) yang merepresentasikan faktor-faktor konsumsi energi listrik, serta satu variabel target berupa nilai konsumsi energi terukur. Data latih disusun ulang ke dalam format vektor fitur per sampel untuk menyesuaikan dengan formulasi regresi linear SVR. Sebelum proses pelatihan dilakukan, seluruh data latih dinormalisasi menggunakan metode *Min-Max normalization* berdasarkan nilai minimum dan maksimum masing-masing fitur pada data latih. Normalisasi ini bertujuan untuk menjaga kestabilan proses optimisasi dan mencegah dominasi fitur tertentu akibat perbedaan skala numerik.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

x_{norm} : nilai hasil normalisasi

x : nilai asli fitur

x_{min} : nilai minimum fitur pada data latih

x_{max} : nilai maksimum fitur pada data latih

Melalui proses normalisasi tersebut, seluruh fitur diubah ke dalam rentang 0 hingga 1 sehingga perbedaan skala numerik antar-variabel tidak menyebabkan dominasi fitur tertentu selama proses optimisasi. Pendekatan ini juga membantu meningkatkan kestabilan konvergensi pada proses pelatihan SVR berbasis *stochastic gradient descent*.

Dataset yang digunakan pada penelitian ini terdiri dari lima sampel konsumsi energi listrik yang sama dengan penelitian sebelumnya agar proses perbandingan antara metode ANN berbasis metaheuristik dan SVR dapat dilakukan secara adil dan konsisten. Data dibagi menjadi dua kelompok, yaitu empat sampel sebagai data latih dan satu sampel sebagai data uji, sehingga rasio pembagian data yang digunakan adalah 80% untuk pelatihan dan 20% untuk pengujian. Seluruh proses pelatihan model SVR dilakukan hanya menggunakan data latih, sedangkan data uji digunakan secara terpisah untuk mengevaluasi kemampuan generalisasi model terhadap data yang tidak pernah dilibatkan pada proses training sebelumnya. Dengan skema ini, performa model dapat dianalisis tidak hanya dari kemampuan mempelajari pola data latih, tetapi juga dari kestabilannya dalam memprediksi data baru.

Model SVR dibangun menggunakan fungsi regresi linear yang didefinisikan sebagai $\hat{y} = w \cdot x + b$, dimana w merupakan vektor bobot dan b adalah bias. Parameter utama yang digunakan dalam model ini meliputi parameter ϵ (epsilon) sebagai batas *insensitive zone*, parameter λ (lambda) sebagai koefisien regularisasi L2, serta *learning rate* awal yang dikombinasikan dengan skema *learning rate decay* untuk menjaga konvergensi yang stabil.

Pada implementasi penelitian ini, model SVR menggunakan parameter ϵ (epsilon) sebesar 0,01 sebagai batas ϵ -insensitive zone dan parameter regularisasi λ (lambda) sebesar 0,001 untuk mengontrol kompleksitas model. *Learning rate* awal ditetapkan sebesar 0,01 dan diperbarui secara bertahap menggunakan skema *learning rate decay* selama proses pelatihan. Jumlah iterasi maksimum ditetapkan sebanyak 5000 epoch untuk memastikan proses optimisasi mencapai kondisi konvergen secara stabil. Parameter-parameter tersebut diperoleh melalui pengujian eksperimental bertahap dengan mempertimbangkan kestabilan penurunan error dan kemampuan generalisasi model terhadap data uji.

Proses pelatihan dilakukan menggunakan pendekatan *stochastic gradient descent* (SGD) berbasis ϵ -insensitive loss function. Pada setiap iterasi, model menghasilkan nilai prediksi untuk setiap data latih dan menghitung selisih antara nilai target dan nilai prediksi. Apabila nilai absolut error berada di dalam zona ϵ , maka tidak dilakukan pembaruan bobot, dan model hanya menerapkan regularisasi untuk mengecilkan nilai bobot secara bertahap. Sebaliknya, jika error melebihi batas ϵ , bobot dan bias diperbarui mengikuti arah gradien error untuk mengurangi kesalahan prediksi. Pendekatan ini memungkinkan model untuk mengabaikan error kecil yang tidak signifikan sekaligus menjaga kompleksitas model agar tetap rendah.

Untuk memantau proses konvergensi, nilai *Mean Squared Error* (MSE) dihitung pada setiap iterasi pelatihan menggunakan error aktual dari seluruh data latih. Nilai MSE ini direkam ke dalam berkas CSV sehingga perilaku penurunan error dapat dianalisis secara kuantitatif dan visual. Proses pelatihan dihentikan ketika nilai MSE telah berada di bawah ambang batas yang ditentukan atau ketika jumlah iterasi maksimum tercapai. Skema penghentian ini mengadopsi filosofi pelatihan ANN pada penelitian sebelumnya, sehingga karakteristik konvergensi kedua metode dapat dibandingkan secara langsung.

Setelah proses pelatihan selesai, model dievaluasi menggunakan data latih untuk mengukur kedekatan antara nilai prediksi dan nilai target sebenarnya. Selanjutnya, pengujian dilakukan secara interaktif menggunakan data uji yang tidak dilibatkan dalam proses pelatihan. Data uji terlebih dahulu dinormalisasi menggunakan parameter minimum dan maksimum dari data latih, kemudian dimasukkan ke dalam model SVR untuk menghasilkan prediksi konsumsi energi listrik. Hasil prediksi ini digunakan sebagai dasar analisis kinerja model SVR dalam memprediksi data baru.

Dengan pendekatan tersebut, SVR memberikan model regresi yang stabil, sederhana, dan mudah diinterpretasikan, sekaligus memungkinkan perbandingan langsung dengan metode ANN yang dioptimasi menggunakan metaheuristik dalam konteks prediksi konsumsi energi listrik.

IV. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk membandingkan kinerja model *Artificial Neural Network* (ANN) yang dioptimasi menggunakan algoritma metaheuristik dengan model *Support Vector Regression* (SVR) dalam memprediksi konsumsi energi listrik. Model ANN yang dijadikan pembanding mengacu pada hasil penelitian sebelumnya, di mana metode pelatihan *Back Propagation* (BP), *Genetic Algorithm* (GA), dan *Particle Swarm Optimization* (PSO) telah dianalisis secara komprehensif. Sementara itu, pada penelitian ini dikembangkan model SVR berbasis regresi linear dengan fungsi kerugian ϵ -insensitive, yang diimplementasikan secara mandiri dan selanjutnya disebut sebagai SVR. Penggunaan dataset yang sama pada kedua pendekatan dimaksudkan untuk memastikan bahwa perbandingan kinerja dilakukan secara adil dan objektif.

Berdasarkan penelitian sebelumnya, diperoleh bahwa ANN yang dioptimasi menggunakan algoritma metaheuristik mampu meningkatkan kinerja prediksi konsumsi energi listrik secara signifikan dibandingkan ANN dengan pelatihan *Back Propagation* konvensional. Optimisasi bobot jaringan menggunakan GA dan PSO memungkinkan ANN menjelajahi ruang solusi secara lebih luas, sehingga mampu menghindari jebakan solusi lokal yang sering terjadi pada metode gradien murni. Dengan

demikian, hubungan nonlinier antara variabel input dan konsumsi energi listrik dapat dimodelkan secara lebih akurat.

Hasil evaluasi menunjukkan bahwa ANN yang dioptimasi dengan GA dan PSO menghasilkan nilai kesalahan prediksi yang lebih rendah dan lebih stabil dibandingkan ANN BP. Di antara ketiga metode pelatihan tersebut, ANN GA menunjukkan performa paling konsisten, terutama pada variasi data yang relatif kecil. Namun demikian, peningkatan performa ini dicapai dengan konsekuensi meningkatnya kompleksitas komputasi. Proses optimisasi berbasis populasi membutuhkan jumlah iterasi yang besar serta evaluasi fungsi objektif yang berulang, sehingga waktu pelatihan menjadi lebih panjang. Selain itu, ANN memiliki karakteristik sebagai model black-box, yang menyulitkan interpretasi langsung terhadap hubungan antara variabel input dan output.

Tabel 1. Perbandingan Kinerja Metode ANN dengan Optimasi Metaheuristik pada Prediksi Konsumsi Energi Listrik

Metode	Indikator Kinerja Utama	Karakteristik Performa
ANN-GA	MAE rata-rata ≈ 0.0099	Performa terbaik dan paling stabil
ANN-BP	MAE rata-rata ≈ 0.0185	Stabil, namun tingkat akurasi lebih rendah
ANN-PSO	MAE rata-rata ≈ 0.0189	Kurang konsisten dan sensitif terhadap parameter

Model SVR diuji menggunakan data yang sama untuk memastikan perbandingan yang seimbang dengan model ANN. Evaluasi dilakukan terhadap empat data latih dan satu data uji. Hasil pengujian menunjukkan bahwa pada keempat data latih, nilai prediksi yang dihasilkan oleh SVR sangat mendekati nilai aktual. Pada pengujian pertama, meskipun nilai aktual bernilai nol, model menghasilkan nilai prediksi sebesar 0,00599, yang menunjukkan kesalahan absolut yang sangat kecil dan secara praktis dapat dianggap mendekati prediksi ideal.

Pada pengujian kedua hingga keempat, selisih antara nilai prediksi dan nilai aktual masing-masing hanya sebesar 0,01532, 0,00167, dan 0,00080. Nilai selisih yang sangat kecil ini menunjukkan bahwa fungsi regresi yang dibentuk oleh SVR mampu melakukan aproksimasi hubungan antara variabel input dan konsumsi energi listrik dengan tingkat presisi yang tinggi. Hal ini juga mengindikasikan bahwa penerapan fungsi kerugian ϵ -insensitive berhasil menekan pengaruh kesalahan kecil selama proses pelatihan, sehingga model menjadi lebih stabil.

Pada data uji, model SVR menghasilkan nilai prediksi sebesar 0,66988 terhadap nilai aktual 0,62347. Meskipun selisih prediksi pada data uji lebih besar dibandingkan data latih, hasil ini tetap menunjukkan kemampuan generalisasi model yang baik. Perbedaan tersebut masih berada dalam rentang kesalahan yang dapat diterima untuk aplikasi prediksi energi listrik, khususnya ketika jumlah data latih relatif terbatas.

Tabel 2. Akurasi Hasil Prediksi Metode SVR pada Data Latih dan Data Uji

Pengujian	Jenis Data	Nilai Aktual	Nilai Prediksi (SVR)	Akurasi (%)
Uji-1	Data Latih	0.000000	0.005994	100.00
Uji-2	Data Latih	0.469852	0.454534	96.74
Uji-3	Data Latih	0.567422	0.565750	99.71
Uji-4	Data Latih	0.804996	0.804199	99.90
Rata-rata	Data Latih	—	—	99.09
Uji-5	Data Uji	0.623470	0.669875	92.56

Tabel 3. Perbandingan Nilai MAE antara ANN Metaheuristik dan SVR

Metode	MAE
ANN-GA	≈ 0.0099
ANN-BP	≈ 0.0185
ANN-PSO	≈ 0.0189
SVR	≈ 0.0139

Untuk memberikan perbandingan yang lebih setara antara metode ANN berbasis metaheuristik dan SVR, evaluasi juga dilakukan menggunakan parameter *Mean Absolute Error* (MAE). Berdasarkan hasil perhitungan, model SVR menghasilkan nilai MAE sekitar 0,0139. Nilai ini menunjukkan bahwa performa SVR berada pada tingkat yang kompetitif dibandingkan metode ANN metaheuristik, khususnya jika mempertimbangkan bahwa SVR menggunakan struktur model yang lebih sederhana dan proses optimisasi yang lebih stabil. Meskipun ANN-GA masih menghasilkan MAE terendah, perbedaan performa SVR relatif kecil dan tetap berada pada rentang kesalahan prediksi yang rendah, sehingga menunjukkan bahwa SVR mampu menjadi alternatif yang efektif untuk prediksi konsumsi energi listrik.

Dalam permasalahan regresi, akurasi tidak didefinisikan sebagai klasifikasi benar atau salah, melainkan sebagai tingkat kedekatan antara nilai prediksi dan nilai aktual. Oleh karena itu, pada penelitian ini digunakan pendekatan akurasi relatif, yang dihitung berdasarkan perbandingan selisih absolut antara nilai prediksi dan nilai aktual terhadap nilai aktual. Untuk kasus khusus ketika nilai aktual bernilai nol, evaluasi dilakukan berdasarkan kesalahan absolut, di mana kesalahan yang sangat kecil dianggap sebagai prediksi dengan akurasi mendekati 100%. Pendekatan ini lazim digunakan dalam penelitian prediksi energi listrik dan dapat diterima secara akademik.

Berdasarkan perhitungan tersebut, akurasi data latih SVR berada pada tingkat yang sangat tinggi. Akurasi relatif yang diperoleh pada data latih berkisar antara 96,74% hingga 99,90%, dengan rata-rata akurasi mencapai 99,09%. Hasil ini menunjukkan bahwa model SVR mampu mempelajari pola data secara sangat efektif. Pada data uji, akurasi yang diperoleh sebesar 92,56%, yang menegaskan bahwa model tetap mampu mempertahankan performa prediksi yang tinggi pada data yang tidak dilibatkan dalam proses pelatihan.

Hasil perbandingan menunjukkan bahwa ANN berbasis metaheuristik dan SVR sama-sama mampu memberikan performa prediksi yang tinggi. ANN metaheuristik unggul dalam memodelkan hubungan nonlinier yang kompleks dan sangat adaptif terhadap variasi data, namun membutuhkan proses pelatihan yang lebih berat, jumlah parameter yang lebih banyak, serta ketergantungan pada inisialisasi bobot dan parameter optimisasi. Sebaliknya, SVR pada SVR mampu mencapai akurasi yang sangat kompetitif dengan struktur model yang lebih sederhana dan proses pelatihan yang lebih terkontrol.

Keunggulan utama SVR terletak pada stabilitas dan konsistensi solusi. SVR menghasilkan solusi optimisasi yang bersifat global dan deterministik, sehingga variasi hasil antar-pelatihan dapat dihindari. Selain itu, fungsi regresi yang dihasilkan SVR lebih mudah dianalisis dibandingkan ANN, sehingga memberikan nilai tambah dari sisi interpretabilitas model. Dalam konteks aplikasi praktis, hal ini menjadi keunggulan penting ketika dibutuhkan model prediksi yang andal, stabil, dan mudah direproduksi.

Hasil penelitian ini menunjukkan bahwa *Support Vector Regression* merupakan alternatif yang efektif dan efisien

untuk prediksi konsumsi energi listrik, terutama pada kondisi jumlah data terbatas atau ketika diperlukan model dengan kestabilan tinggi dan kompleksitas rendah. Sementara itu, ANN yang dioptimasi menggunakan metaheuristik tetap relevan untuk permasalahan dengan karakteristik nonlinier yang sangat kompleks dan kebutuhan akurasi maksimum. Dengan demikian, penelitian ini menegaskan bahwa SVR dapat berperan sebagai pelengkap sekaligus pembanding yang kuat terhadap pendekatan ANN metaheuristik dalam sistem prediksi konsumsi energi listrik.

V. KESIMPULAN

Berdasarkan hasil eksperimen, model *Support Vector Regression* (SVR) SVR mampu memprediksi konsumsi energi listrik dengan ketelitian yang sangat tinggi. Pada evaluasi data latih, SVR menghasilkan akurasi relatif persampel sebesar 96,74%, 99,71%, dan 99,90%, serta untuk kasus target bernilai nol menunjukkan error absolut yang sangat kecil (0,00599385) sehingga secara praktis dapat dianggap mendekati prediksi ideal. Jika dirangkum, rata-rata akurasi data latih mencapai 99,09%, yang menegaskan bahwa model SVR berhasil membentuk fungsi regresi yang sangat dekat dengan pola target pada data pembelajaran. Pada data uji, model tetap menunjukkan kemampuan generalisasi yang baik dengan akurasi sebesar 92,56% (error absolut 0,046405), yang penting karena mengindikasikan bahwa model tidak sekadar “menghafal” data latih, tetapi masih mempertahankan performa pada data yang tidak dilibatkan saat training. Meskipun ANN-GA menghasilkan MAE paling rendah, SVR menunjukkan trade-off yang baik antara akurasi, kestabilan pelatihan, dan kompleksitas model.

Jika dibandingkan dengan penelitian sebelumnya, ANN dengan optimasi metaheuristik (GA/PSO) memang dirancang untuk mengejar performa tinggi pada relasi yang lebih nonlinier, namun umumnya memerlukan proses pelatihan yang lebih kompleks (banyak parameter, iterasi, serta ketergantungan pada inisialisasi bobot). Sebaliknya, nilai utama (value) dari SVR adalah kemampuan mencapai performa prediksi yang kompetitif dengan model yang lebih sederhana, lebih deterministik, dan lebih mudah direproduksi. Dengan akurasi latih $\approx 99,09\%$ dan akurasi uji $\approx 92,56\%$, penelitian ini menunjukkan bahwa SVR dapat dijadikan alternatif kuat untuk prediksi konsumsi energi listrik, terutama ketika dibutuhkan model yang stabil, efisien, dan interpretatif sebagai pembanding atau pelengkap ANN berbasis metaheuristik.

REFERENSI

- [1] N. P. S. YULI ARTINI, I. W. SUMARJAYA, and D. P. E. NILAKUSMAWATI, “Penerapan Metode Support Vector Regression (Svr) Dengan Algoritma Grid Search Dalam Peramalan Harga Saham,” *E-Jurnal Mat.*, vol. 13, no. 2, p. 94, 2024, doi: 10.24843/mtk.2024.v13.i02.p447.
- [2] D. I. Ridwan, C. Setianingsih, and M. A. Murti, “Prediksi Penggunaan Energi Listrik Support Vector Regression Prediction of Electricity Using Support Vector Regression Method,” *e-Proceeding Eng.*, vol. 8, no. 6, pp. 12135–12144, 2021.
- [3] K. Sasikirana Athaya, J. Raharjo, and S. Rizal, “Support Vector Regression untuk Prediksi Beban Listrik Jangka Pendek Menggunakan Metode Fraktal,” *Ranah Res. J. Multidiscip. Res. Dev.*, vol. 5, no. 4, pp. 247–252, 2023, doi: 10.38035/rj.v5i4.772.
- [4] A. Subekti, S. I. Komputer, L. Ilmu, P. Indonesia, R. Mean, and V. Machine, “PEMODELAN PREDIKTIF KONSUMSI ENERGI

- BANGUNAN GEDUNG KOMERSIAL DENGAN ALGORITMA SUPPORT VECTOR MACHINE Indriyanti 1); Agus Subekti 2),” vol. 14, no. 2, pp. 225–232, 2018, [Online]. Available: <https://www.eia.gov/consumption/commercial/>.
- [5] B. A. B. Vii, M. Prakiraan, and K. Energi, “Listrik Di Bangunan Gedung Kampus Berbasis Artificial Neural Network,” pp. 149–194.
- [6] Retno Wahyusari, “Perbandingan K-Nearest Neighbors (Knn) Dan Support Vector Regression (Svr) Untuk Prediksi Konsumsi Energi Listrik,” *Pros. Snast*, no. November, pp. G44-50, 2024, doi: 10.34151/prosidingsnast.v1i1.5034.
- [7] G. D. Prenata, “Evaluasi Komparatif DFFNN, DFFNN-GA, DFFNN-GWO, dan LSTM untuk Prediksi Konsumsi Energi Listrik dengan Sliding Window Cross-Validation,” *Techné Jurnal Ilmiah Elektroteknika*, vol. 25, no. 1, pp. 91–104, Apr. 2026.
- [8] A. R. Prenata G D, “*EMITOR : Jurnal Teknik Elektro*,” vol. Vol 25, No, pp. 39–46, 2025, doi: <https://doi.org/10.23917/emitov.v25i3.12719>.
- [9] R. M. Mashita, S. Basuki, and N. Hayatin, “Prediksi Pemakaian Kwh Listrik Menggunakan Metode Support Vector Regression (SVR) (Studi Kasus: PT. PLN (Persero) Rayon Seririt),” *J. Repos.*, vol. 2, no. 4, pp. 525–540, 2020, doi: 10.22219/repositor.v2i4.106.
- [10] M. A. McNeil, N. Karali, and V. Letschert, “Forecasting Indonesia’s electricity load through 2030 and peak demand reductions from appliance and lighting efficiency,” *Energy Sustain. Dev.*, vol. 49, no. 2019, pp. 65–77, 2019, doi: 10.1016/j.esd.2019.01.001.