

PREDIKSI SUHU UDARA DENGAN ALGORITMA *ARTIFICIAL NEURAL NETWORK* DI JAWA TIMUR

Karnisih¹, Sunarno², Iqbal³
Universitas Negeri Semarang^{1,2}
Badan Meteorologi Klimatologi dan Geofisika³
karniwigianto@students.unnes.ac.id¹

ABSTRAK

Penelitian ini bertujuan untuk mengoptimasi hyperparameter *Artificial Neural Network* (ANN) secara sistematis berbasis algoritma guna memperoleh konfigurasi terbaik, serta membandingkan akurasi prediksi suhu udara antara ANN dan beberapa algoritma machine learning lainnya. Proses seleksi fitur dilakukan menggunakan pendekatan fisis untuk menentukan variabel yang berpengaruh terhadap suhu udara, sedangkan optimasi *hyperparameter* ANN dilakukan dengan metode *Random Search*. Model ANN dibandingkan dengan *Linear Regression* (LR), *Random Forest* (RF), dan *Support Vector Regression* (SVR) dalam memprediksi suhu udara. Evaluasi kinerja model dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model ANN secara umum menghasilkan nilai MSE, RMSE, MAE, dan MAPE yang lebih rendah serta nilai R^2 yang lebih tinggi dibandingkan metode lainnya pada empat lokasi penelitian, yaitu Banyuwangi, Juanda, Sangkapura, dan Pasuruan. Temuan ini menunjukkan bahwa ANN dengan optimasi hyperparameter yang tepat mampu memberikan akurasi prediksi suhu udara yang lebih baik.

Kata Kunci: *Artificial Neural Network*, Jawa Timur, *Machine Learning*, Suhu Udara,

ABSTRACT

This study aims to systematically optimize the hyperparameters of an Artificial Neural Network (ANN) using an algorithm-based approach to obtain the best configuration, as well as to compare the air temperature prediction accuracy of ANN with other machine learning algorithms. Feature selection was performed using a physical approach to identify variables that significantly influence air temperature, while ANN hyperparameter optimization was conducted using the Random Search method. The ANN model was compared with Linear Regression (LR), Random Forest (RF), and Support Vector Regression (SVR) in predicting air temperature. Model performance was evaluated using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2). The results indicate that the ANN model generally achieved lower MSE, RMSE, MAE, and MAPE values and higher R^2 values compared to the other methods across four study locations: Banyuwangi, Juanda, Sangkapura, and Pasuruan. These findings

demonstrate that ANN with properly optimized hyperparameters can provide more accurate air temperature predictions..

Keywords: *Artificial Neural Network, East Java, Machine Learning, Air Temperature,*

PENDAHULUAN

Perubahan iklim merupakan permasalahan global yang semakin mendapat perhatian dalam beberapa dekade terakhir karena dampaknya yang luas terhadap lingkungan, kesehatan manusia, pertanian, hingga stabilitas ekonomi dunia (Nita et al., 2024). Salah satu indikator paling nyata dari perubahan iklim adalah fluktuasi suhu udara yang terjadi di seluruh permukaan bumi. Peningkatan konsentrasi gas rumah kaca akibat aktivitas manusia telah mempercepat perubahan iklim dengan laju yang tidak dapat diprediksi, sehingga mempengaruhi pola distribusi suhu secara signifikan (Mats et al., 2025; Nita et al., 2024).

Suhu udara merupakan salah satu parameter utama dalam sistem meteorologi yang memiliki peran signifikan terhadap berbagai sektor kehidupan, seperti pertanian, pariwisata, transportasi, dan energi (Hidayatullah & Cherid, 2023; Irmiza Putri et al., 2023; Li et al., 2023). Kasus pada sektor pertanian, suhu udara mempengaruhi berbagai proses fisiologis tanaman. Suhu yang tidak sesuai dapat mengganggu waktu tanam, serta meningkatkan risiko serangan hama dan penyakit, yang pada akhirnya berpotensi menurunkan produktivitas pertanian secara signifikan (M. Farhan Harahap et al., 2026).

Perubahan suhu udara tidak hanya berdampak pada aktivitas manusia sehari-hari, tetapi juga berkontribusi terhadap dinamika ekosistem dan perubahan lingkungan global, seperti penurunan keanekaragaman hayati, peningkatan

erosi tanah, kenaikan permukaan laut, serta fenomena pemanasan global (Cifuentes et al., 2020). Dalam konteks perubahan iklim, suhu udara sering dijadikan sebagai indikator utama untuk memantau dan menganalisis kondisi lingkungan yang terus berubah (Yakut & Süzülmüş, 2020). Oleh karena itu, prediksi dan prakiraan suhu yang akurat menjadi sangat penting guna mendukung pengambilan keputusan, perencanaan kegiatan, serta upaya mitigasi risiko bencana yang berkaitan dengan cuaca ekstrem. Melalui pendekatan ilmiah yang tepat, informasi mengenai suhu udara dapat memberikan kontribusi besar dalam menjaga keseimbangan lingkungan dan meningkatkan ketahanan masyarakat terhadap dampak perubahan iklim (Li et al., 2023).

Metode prediksi suhu udara dalam kurun waktu lima tahun terakhir telah banyak menggunakan pendekatan berbasis *machine learning* (ML). Hal ini disebabkan karena kemampuan metode ML dalam mengelola data besar, menangkap pola non-linier, dan menyesuaikan model terhadap dinamika atmosfer yang kompleks. Algoritma ML seperti *Linear Regression* (LR), *Decision Tree* (DT), *Random Forest* (RF), *k-Nearest Neighbor* (kNN), dan *Support Vector Machine* (SVM) merupakan algoritma yang banyak digunakan dalam penelitian prediksi suhu udara dalam beberapa tahun terakhir dan menghasilkan model prediksi suhu udara dengan akurasi yang baik (Azari et al., 2022; Hoo et al., 2024; Xiong, 2025). Namun, penelitian-penelitian

tersebut belum menggunakan metode *Artificial Neural Network* (ANN) sebagai pembanding sehingga variasi akurasi prediksi suhu udara yang lebih komprehensif belum dapat diketahui, sedangkan ANN telah terbukti memiliki performa prediksi data hidrologi yang baik pada banyak penelitian terakhir (Aizansi et al., 2024; Sušanĳ Čule et al., 2025; Zemnazi et al., 2024).

Sebagian penelitian terakhir sudah mencoba menggunakan metode ANN untuk prediksi suhu udara, namun metode *hyperparameter tuning* yang dilakukan masih dilakukan secara manual menggunakan *trial and error* bahkan ada juga yang tidak melakukan tuning hyperparameter ANN. Hal ini dapat mempengaruhi akurasi model prediksi suhu udara menjadi kurang maksimal (Azari et al., 2022; Himawan et al., 2023; Xiong, 2025).

Berbeda dari penelitian sebelumnya, penelitian ini diimbangi dengan optimasi *hyperparameter* model ANN yang lebih sistematis menggunakan metode *random search*, yang memungkinkan pencarian ruang hyperparameter ANN yang lebih efisien dan efektif.

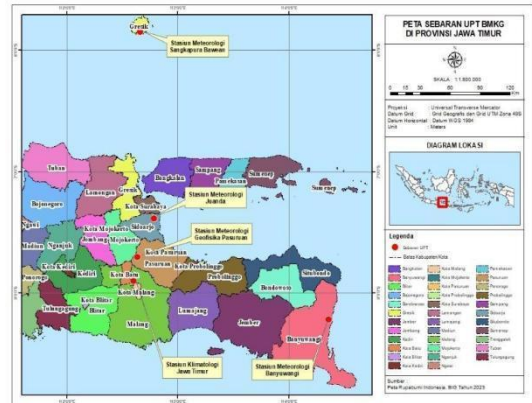
Berdasarkan latar belakang tersebut, pada penelitian ini dilakukan pengujian prediksi suhu udara menggunakan metode *machine learning* ANN dengan *hyperparameter tuning* yang dioptimasi secara otomatis berbasis algoritma dan dilakukan pemilihan fitur berdasarkan faktor fisis pada bagian *preprocessing* dengan tujuan untuk meningkatkan akurasi prediksi suhu udara.

METODE PENELITIAN

Tempat dan Waktu Penelitian

Penelitian ini dilakukan mulai bulan Februari sampai dengan bulan Juli 2025 dengan lokasi penelitian di beberapa wilayah Provinsi Jawa Timur. Pemilihan Jawa Timur didasarkan pada

kombinasi antara kompleksitas geografis, ketersediaan data, relevansi ekonomi, dan pentingnya untuk kajian perubahan iklim. Sebaran lokasi stasiun MKG di Jawa Timur ditunjukkan pada Gambar 1.



Gambar 1.
Peta Lokasi Stasiun MKG di Jawa Timur

Data Penelitian

Penelitian ini menggunakan data yang bersumber dari Badan Meteorologi Klimatologi dan Geofisika (BMKG) untuk beberapa wilayah di Provinsi Jawa Timur dengan periode data dari tahun 2019 sampai dengan Bulan Juni 2024 dengan parameter data *Temperatur Average* (TAV), *Relative Humidity* (RH), *Wind Speed Average* (WAV), *Wind Direction* (WD), *Wind Speed Max* (WSM), *Rainfall* (RR), *Pressure* (PPP), *Sunshine* (SUN) dan Titik Embun (*Dew Point*). Tabel 3.2 merupakan contoh dataset pada lokasi Stasiun Meteorologi Juanda Surabaya.

Tabel 1.
Dataset Stasiun Meteorologi Juanda Surabaya

No	TAV	RR	SUN	WAV
1	29.0	0	5.2	4.8
2	28.5	0	4	3.5
3	25.6	6.8	4	1.4
4	27.6	38.5	0	1.8
5	29.2	1	2.8	1.9
6	28.9	0	5	2.6

7	28.3	0	5.2	2.5
8	29.1	6.4	7.2	2.2
...
2016	28.4	0	9.1	2.1

Prosedur Kerja

Prosedur penelitian ini meliputi beberapa tahapan. Pertama, pengumpulan data iklim dari beberapa stasiun pengamatan di Jawa Timur untuk periode 2019 hingga Juni 2024. Kedua, preprocessing data yang mencakup penghapusan anomali dan nilai ekstrim, penanganan missing values (imputasi/interpolasi), normalisasi atau standarisasi, serta pembagian data menjadi 80% data latih dan 20% data uji. Ketiga, seleksi fitur menggunakan pendekatan fisis untuk menentukan variabel yang berpengaruh terhadap prediksi suhu udara. Selanjutnya dilakukan hyperparameter tuning pada model ANN dengan metode random search guna memperoleh arsitektur optimal. Model prediksi kemudian dibangun menggunakan empat algoritma machine learning, yaitu LR, SVR, RF, dan ANN, melalui proses pelatihan dan pengujian. Evaluasi kinerja model dilakukan menggunakan metrik yaitu Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE) dan koefisien determinasi (R^2) untuk menentukan model dengan akurasi prediksi suhu udara terbaik yang dapat diterapkan di wilayah Jawa Timur.

Artificial Neural Network

Artificial Neural Network (ANN) adalah algoritma untuk pemrosesan yang mempunyai kemiripan dengan sistem informasi saraf manusia. ANN memiliki keunggulan dalam mentoleransi kesalahan sehingga dapat


menghasilkan prediksi yang akurat (Muthiah et al., 2021).

Dalam metode jaringan syaraf tiruan (ANN), algoritma *backpropagation* adalah salah satu metode yang sering digunakan. Algoritma ini dikenal luas karena efektifitas, popularitas, dan kemudahannya untuk dipelajari, terutama dalam jaringan multilayer yang kompleks (Novitasari et al., 2020).

Hyperparameter Tuning

Penelitian ini menggunakan algoritma *random search* untuk pencarian model ANN terbaik dengan mengevaluasi berbagai kombinasi *hyperparameter* yang telah ditentukan secara acak, dengan tujuan untuk mengurangi waktu yang dibutuhkan dalam proses pelatihan ANN (Putri et al., 2023).

Meskipun titik-titik yang dipilih tidak selalu merepresentasikan solusi optimal, hasilnya tetap mampu menghasilkan model ANN dengan kinerja yang cukup baik (Fordana & Rochmawati, 2022). Ilustrasi alur kerja dari algoritma *random search* dapat dilihat pada Gambar 2.



Gambar 2.
Alur Kerja Algoritma *Random Search*

Setiap lapisan pada ANN memiliki sejumlah parameter penting yang perlu dioptimalkan melalui metode *random search*. Proses optimisasi ini akan dilakukan secara berulang guna memperoleh kombinasi *hyperparameter* yang menghasilkan nilai *validation accuracy* tertinggi. Rentang nilai untuk masing-masing *hyperparameter* disajikan pada Tabel 2.

Tabel 2.
Rentang Pencarian *Hyperparameter* ANN

Parameter	Rentang
hidden layer	1-2
jumlah neuron	8-100
batch size	4, 8, 16
fungsi aktivasi	rectified linear unit (ReLU), hyperbolic tangent (Tanh), sigmoid
optimizer	adam, rmsprop, SDG
learning rate	0.00001-0.01
epochs	100-500

HASIL PENELITIAN

Hyperparameter Tuning ANN

Tujuan dari pengujian ini adalah untuk mengidentifikasi konfigurasi terbaik yang mampu menghasilkan

akurasi model paling optimal. Tabel 3 menyajikan hasil konfigurasi *hyperparameter tuning* ANN yang didapatkan dengan pencarian otomatis menggunakan metode *random search*. Setiap konfigurasi dinilai berdasarkan skor akurasi yang diperoleh setelah proses pelatihan selesai. Fokus utama analisis adalah evaluasi performa berdasarkan kombinasi berbagai *hyperparameter* yang telah diuji, antara lain ukuran *hidden layer*, *batch size*, jumlah *epoch*, jenis *optimizer*, *learning rate*, serta fungsi aktivasi.

Sesuai hasil yang disajikan pada Tabel 3, dapat disimpulkan bahwa konfigurasi terbaik diperoleh pada model nomor 1, dengan skor akurasi sebesar 0,894. Model ini menggunakan dua *hidden layer* berukuran 8 dan 10 neuron, *batch size* sebesar 4, serta dilatih selama 300 *epoch* dan kombinasi fungsi aktivasi ReLU pada lapisan pertama serta Sigmoid pada lapisan kedua. Kombinasi ini terbukti menghasilkan stabilitas pelatihan yang baik dan kemampuan klasifikasi yang optimal.

Tabel 3.
Hasil *Hyperparameter Tuning*
ANN Menggunakan *Random Search*

No	<i>Hidden Layer Size</i>		<i>Batch Size</i>	<i>Epoch</i>	<i>Optimizer</i>	<i>Learning Rate</i>	<i>Activation Function</i>		<i>Score</i>
	1	2					1	2	
1	8	10	4	300	Adam	0,0010	ReLU	Sigmoid	0,894
2	8	10	4	300	Adam	0,0007	ReLU	Sigmoid	0,893
3	16	8	4	200	Adam	0,0010	ReLU	ReLU	0,892
4	30	20	16	500	RMSprop	0,0001	ReLU	ReLU	0,891
5	16	-	8	500	Adam	0,0001	ReLU	-	0,891
6	20	8	4	200	Adam	0,0005	Sigmoid	ReLU	0,890

No	Hidden Layer Size		Batch size	Epoch	Optimizer	Learning Rate	Activation Function		Score
	1	2					1	2	
7	20	8	8	400	RMSprop	0,0006	Tanh	Sigmoid	0,889
8	8	10	8	400	Adam	0,0002	ReLU	Tanh	0,886
9	20	30	8	400	RMSprop	0,0002	Sigmoid	ReLU	0,882
10	16	-	8	100	Adam	0,0010	Tanh	-	0,881

Pengujian Prediksi Suhu Udara

Tujuan dari pengujian ini adalah untuk membandingkan performa empat metode pemodelan *machine learning*, yaitu ANN, LR, RF, dan SVR dalam memprediksi suhu udara harian di wilayah Jawa Timur. Sejumlah parameter konfigurasi diterapkan untuk model ANN, RF, dan SVR. Model ANN menggunakan konfigurasi arsitektur terbaik sesuai dengan hasil nomor satu pada hyperparameter tuning Tabel 3.

Model LR, tidak dilakukan konfigurasi parameter secara eksplisit. Dengan demikian, model secara default memanfaatkan persamaan regresi linier berganda sebagaimana ditunjukkan pada persamaan 1 untuk melakukan prediksi terhadap variabel dependen, yaitu suhu udara.

Model RF yang digunakan dalam penelitian ini dikonfigurasi pada beberapa parameter diantaranya jumlah pohon sebanyak 15 pohon ($n_{estimator}=15$), fungsi kerugian yang digunakan untuk mengukur kualitas pemisahan adalah *mean squared error* ($criterion='squared_error'$), jumlah fitur yang dipilih tiap split

menggunakan akar kuadrat dari jumlah total fitur yang tersedia ($max_features='sqrt'$), membutuhkan minimum 2 sampel agar suatu node dapat dipecah ($min_samples_split=2$), dan setiap daun dalam pohon harus memiliki setidaknya satu sampel ($min_samples_leaf=1$). Untuk menjamin reproduktibilitas hasil, parameter $random_state$ disetel ke nilai 2 ($random_state=2$) yang berfungsi sebagai penentu seed pada proses pelatihan model.

Model SVR dikonfigurasi dengan kernel *nonlinear* yaitu *radial basis function* (RBF), nilai $C=10$, $gamma=0.1$, dan $epsilon=0.1$. Parameter-parameter tersebut dipilih untuk mengontrol margin toleransi kesalahan, sensitivitas terhadap jarak antar titik data, serta penalti terhadap kesalahan prediksi di luar margin. Selain itu, parameter max_iter yang digunakan yaitu -1 ($max_iter=1$), yang berarti proses pelatihan model tidak dibatasi oleh jumlah iterasi maksimal. Dengan demikian, optimisasi akan terus berjalan hingga mencapai konvergensi.

Tabel 4.
Hasil Pengujian
Prediksi Suhu Udara di Stasiun Banyuwangi

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
1	<i>ANN</i>	0,211 ± 0,007	0,459 ± 0,007	1,309 ± 0,019	0,358 ± 0,005	0,864 ± 0,004
2	<i>RL</i>	0,219 ± 0,007	0,468 ± 0,008	1,330 ± 0,018	0,364 ± 0,005	0,858 ± 0,003
3	<i>RF</i>	0,267 ± 0,012	0,516 ± 0,012	1,462 ± 0,038	0,401 ± 0,011	0,826 ± 0,007
4	<i>SVR</i>	0,260 ± 0,050	0,629 ± 0,170	1,306 ± 0,021	0,358 ± 0,006	0,863 ± 0,002

Tabel 5.
Hasil Pengujian
Prediksi Suhu Udara di Stasiun Pasuruan

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
1	<i>ANN</i>	0,186 ± 0,019	0,428 ± 0,022	1,493 ± 0,061	0,326 ± 0,013	0,811 ± 0,013
2	<i>RL</i>	0,187 ± 0,019	0,430 ± 0,022	1,512 ± 0,057	0,328 ± 0,014	0,809 ± 0,013
3	<i>RF</i>	0,255 ± 0,026	0,502 ± 0,025	1,717 ± 0,051	0,374 ± 0,011	0,741 ± 0,012
4	<i>SVR</i>	0,187 ± 0,017	0,432 ± 0,019	1,522 ± 0,052	0,334 ± 0,012	0,808 ± 0,013

Tabel 6.
Hasil Pengujian
Prediksi Suhu Udara di Stasiun Juanda

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
1	<i>ANN</i>	0,161 ± 0,008	0,401 ± 0,010	1,121 ± 0,030	0,315 ± 0,009	0,871 ± 0,005
2	<i>RL</i>	0,163 ± 0,007	0,403 ± 0,009	1,127 ± 0,026	0,317 ± 0,008	0,870 ± 0,005
3	<i>RF</i>	0,204 ± 0,007	0,457 ± 0,009	1,270 ± 0,022	0,364 ± 0,008	0,838 ± 0,003

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
4	SVR	0,162 ± 0,007	0,402 ± 0,009	1,130 ± 0,026	0,317 ± 0,007	0,871 ± 0,004

Tabel 7.
Hasil Pengujian
Prediksi Suhu Udara di Stasiun Malang

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
1	ANN	0,373 ± 0,008	0,610 ± 0,006	1,421 ± 0,351	0,426 ± 0,002	0,700 ± 0,008
2	RL	0,381 ± 0,009	0,617 ± 0,007	1,802 ± 0,004	0,432 ± 0,001	0,694 ± 0,009
3	RF	0,403 ± 0,013	0,635 ± 0,010	1,395 ± 0,316	0,737 ± 0,284	0,676 ± 0,012
4	SVR	0,358 ± 0,006	0,598 ± 0,005	1,745 ± 0,015	0,419 ± 0,003	0,712 ± 0,008

Tabel 8.
Hasil Pengujian
Prediksi Suhu Udara di Stasiun Sangkapura

No	Metode	Matrik Evaluasi				
		MSE	RMSE	MAP E (%)	MAE	R ²
1	ANN	0,119 ± 0,005	0,345 ± 0,007	0,937 ± 0,016	0,264 ± 0,005	0,891 ± 0,006
2	RL	0,119 ± 0,005	0,345 ± 0,007	0,941 ± 0,018	0,265 ± 0,005	0,891 ± 0,006
3	RF	0,143 ± 0,005	0,377 ± 0,006	1,034 ± 0,018	0,292 ± 0,005	0,870 ± 0,007
4	SVF	0,129 ± 0,004	0,358 ± 0,006	0,988 ± 0,016	0,279 ± 0,005	0,882 ± 0,007

PEMBAHASAN

Hasil prediksi suhu udara di Stasiun Banyuwangi pada Tabel 4, model ANN menunjukkan performa terbaik dibandingkan model lainnya. Model ini menghasilkan nilai MSE

sebesar 0,211 ± 0,007, MAE 0,358 ± 0,005, dan R² sebesar 0,864 ± 0,004, yang merupakan nilai tertinggi di antara seluruh model. Regresi Linier dan SVR menunjukkan performa yang mendekati ANN, dengan nilai R²

masing-masing 0,858 dan 0,863, meskipun sedikit lebih rendah. Model Random Forest mencatat performa paling rendah dengan nilai MSE tertinggi ($0,267 \pm 0,012$) dan R^2 terendah ($0,826 \pm 0,007$), yang menunjukkan model ini kurang cocok digunakan di wilayah ini.

Hasil pengujian di Stasiun Pasuruan pada Tabel 5, model ANN kembali memberikan hasil terbaik dengan nilai R^2 sebesar $0,811 \pm 0,013$ dan MAE terendah ($0,326 \pm 0,013$). Regresi Linier dan SVR memiliki performa yang sangat mirip, dengan perbedaan R^2 dan MAE yang sangat kecil dibanding ANN, masing-masing sebesar 0,809 dan 0,808. Namun, model Random Forest mencatat hasil yang kurang baik, dengan R^2 hanya sebesar $0,741 \pm 0,012$ dan MAE sebesar $0,374 \pm 0,011$, yang menunjukkan tingkat kesalahan yang lebih tinggi dalam prediksi suhu di lokasi ini.

Perbedaan performa antar model semakin kecil pada stasiun Juanda seperti terlihat pada Tabel 6. ANN dan SVR mencatatkan nilai R^2 tertinggi sebesar 0,871, dengan nilai MAE hampir identik yaitu 0,315 untuk ANN dan 0,317 untuk SVR. Regresi Linier juga memiliki performa yang kompetitif, dengan R^2 0,870 dan MAE 0,317. Meskipun demikian, model Random Forest tetap menunjukkan performa yang lebih rendah, dengan R^2 sebesar 0,838 dan MAE 0,364. Hasil ini menunjukkan bahwa semua model regresi linier dan nonlinier mampu menangani data dari lokasi Juanda dengan baik, namun ANN dan SVR masih sedikit lebih unggul.

Model SVR pada wilayah Malang secara keseluruhan menghasilkan performa terbaik seperti

yang disajikan pada Tabel 7 berdasarkan nilai MSE ($0,358 \pm 0,006$) dan R^2 ($0,712 \pm 0,008$), melebihi ANN dan Regresi Linier. Namun, ANN masih memberikan hasil yang sangat kompetitif dengan R^2 0,700, serta MAE yang lebih rendah dari Regresi Linier dan Random Forest. Random Forest menunjukkan performa yang paling buruk secara konsisten, khususnya dengan MAE yang jauh lebih tinggi ($0,737 \pm 0,284$) dan R^2 paling rendah ($0,676 \pm 0,012$), mengindikasikan ketidaksesuaian model ini terhadap karakteristik data suhu udara wilayah Jawa Timur.

Berdasarkan hasil pengujian model prediksi suhu udara pada lima lokasi stasiun cuaca yaitu Banyuwangi, Pasuruan, Juanda, Jawa Timur, dan Sangkapura, dapat disimpulkan bahwa model Artificial Neural Network secara umum memberikan kinerja prediksi terbaik dan paling konsisten dibandingkan metode lainnya, yaitu Regresi Linier, Random Forest, dan Support Vector Regression.

Model ANN menunjukkan nilai MSE dan MAE yang lebih rendah serta nilai koefisien determinasi (R^2) yang lebih tinggi di hampir semua lokasi pengujian, menandakan bahwa model ini mampu menangkap pola data dan memberikan hasil prediksi yang akurat serta stabil. Keunggulan ini paling jelas terlihat di stasiun Banyuwangi, Pasuruan, dan Juanda, yaitu perbedaan performa antara ANN dan model lain cukup signifikan.

Meskipun Regresi Linier dan SVR juga menunjukkan performa yang baik, khususnya di lokasi seperti Juanda dan Sangkapura, hasilnya cenderung lebih terbatas terutama dalam menghadapi kompleksitas pola

suhu udara yang nonlinier. Random Forest, meskipun termasuk dalam kategori model nonlinier, justru memberikan hasil yang paling rendah di sebagian besar lokasi, ditunjukkan dengan nilai error yang tinggi dan R^2 yang rendah, sehingga dianggap kurang cocok untuk kasus prediksi suhu udara pada dataset ini.

Secara keseluruhan, dapat disimpulkan bahwa ANN adalah metode paling optimal untuk prediksi suhu udara harian di wilayah Jawa Timur, karena mampu menghasilkan model dengan akurasi tinggi dan tingkat kesalahan yang rendah secara konsisten di berbagai kondisi lokasi stasiun pengamatan.

SIMPULAN

Model ANN dengan *hyperparameter tuning* terbukti menghasilkan performa terbaik dalam memprediksi suhu udara harian di wilayah yaitu Banyuwangi, Pasuruan, Juanda, Jawa Timur, dan Sangkapura dibandingkan dengan metode *Regresi Linier*, *Random Forest*, dan *Support Vector Regression*. Hal ini ditunjukkan oleh nilai evaluasi model yang konsisten lebih baik, seperti nilai MSE dan MAE yang lebih rendah, serta nilai R^2 yang lebih tinggi di hampir semua lokasi pengujian yang menandakan bahwa model ANN mampu menangkap pola data dan memberikan hasil prediksi yang akurat serta stabil. Keunggulan ini paling jelas terlihat di stasiun Banyuwangi, Pasuruan, dan Juanda, yaitu perbedaan performa antara ANN dan model lain cukup signifikan.

Terakhir, pada stasiun Sangkapura yang disajikan pada Tabel 8, semua model menunjukkan performa yang sangat baik dengan

perbedaan metrik yang sangat kecil. ANN dan Regresi Linier sama-sama memperoleh nilai MSE dan RMSE identik (0,119 dan 0,345) serta R^2 sebesar $0,891 \pm 0,006$, menunjukkan bahwa baik model linier maupun non linier dapat digunakan secara efektif untuk prediksi suhu udara di lokasi ini. Meski demikian, ANN masih sedikit lebih unggul dalam hal MAE dan MAPE. Random Forest dan SVR juga menunjukkan performa baik, meskipun sedikit di bawah ANN dan Regresi Linier, dengan R^2 masing-masing 0,870 dan 0,882.

DAFTAR PUSTAKA

- Aizansi, A. N., Ogunjobi, K. O., & Ogou, F. K. (2024). Monthly Rainfall Prediction Using Artificial Neural Network (case study: Republic of Benin). *Environmental Data Science*, 3, 1–25. <https://doi.org/10.1017/eds.2024.10>
- Azari, B., Hassan, K., Pierce, J., & Ebrahimi, S. (2022). Evaluation of Machine Learning Methods Application in Temperature Prediction. *Computational Research Progress in Applied Science & Engineering*, 8(1), 1–12. <https://doi.org/10.52547/crpase.8.1.2747>
- Cifuentes, J., Marulanda, G., Bello, A., & Reneses, J. (2020). Air Temperature Forecasting Using Machine Learning Techniques: A Review. *Energies*, 13(6), 1–28. <https://doi.org/10.3390/en13164215>
- Fordana, M. D. Y., & Rochmawati, N. (2022). Optimisasi Hyperparameter CNN

- Menggunakan Random Search Untuk Deteksi COVID-19 Dari Citra X-Ray Dada. *Journal of Informatics and Computer Science (JINACS)*, 4(01), 10–18. <https://doi.org/10.26740/jinacs.v4n01.p10-18>
- Hidayatullah, S., & Cherid, A. (2023). Prediksi Temperatur Cuaca di Negara Norwegia Menggunakan Metode LSTM. *Simkom*, 8(2), 187–198. <https://doi.org/10.51717/simkom.v8i2.192>
- Himawan, S. N., Sohiburoyyan, R., & Iryanto, I. (2023). Hyperparameter Tuning on Graph Neural Network for the Classification of SARS-CoV-2 Inhibitors. *Journal of Applied Informatics and Computing*, 7(2), 186–191. <https://doi.org/10.30871/jaic.v7i2.6735>
- Hoo, P. C., Zuraidin, N., & Safar, M. (2024). AITCS Comparative Analysis of Machine Learning Algorithms on Temperature and Wind Speed Prediction. 5(2), 446–460.
- Irmiza Putri, Putri Balqis, Dhia Uddin, Zuhra Adha, Rahmi Fadhilah, & Samsul Anwar. (2023). *Envirotek : Jurnal Ilmiah Teknik Lingkungan*. *Envirotek : Jurnal Ilmiah Teknik Lingkungan*, 15(1), 13–21. <https://doi.org/https://doi.org/10.33005/envirotek.v15i1.215>
- Li, Y., Li, T., Lv, W., Liang, Z., & Wang, J. (2023). Prediction of Daily Temperature Based on the Robust Machine Learning Algorithms. *Sustainability (Switzerland)*, 15(12). <https://doi.org/10.3390/su15129289>
- M. Farhan Harahap, Akbar Syam Ramadhan, Faiq Raihan Zaky Siaregar, Ridho Saputra, Rassid Dwi A Matondang, & Hari Gunawan. (2026). Analisis Pengaruh Suhu dan Kelembaban terhadap Efisiensi Fotosintesis dan Produktivitas TBS Tanaman Kelapa Sawit. *AGRO ESTATE Jurnal Budidaya Perkebunan Kelapa Sawit Dan Karet Available*, 9(2), 86–94.
- Mats, A., Mitryasova, O., Salamon, I., & Kochanek, A. (2025). Atmospheric Air Temperature as An Integrated Indicator of Climate Change. *Ecological Engineering and Environmental Technology*, 26(3), 352–360. <https://doi.org/10.12912/27197050/200307>
- 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.
- Nita, L. T., Prawito, P., Sudjmitko, S., & Anwar, A. (2024). Climate Change: A Study of Air Temperature Trend and Variation in the City of Bengkulu. *AGRITROPICA: Journal of Agricultural Sciences*, 7(1), 1–9. <https://doi.org/10.31186/j.agritropica.7.1.1-9>
- Novitasari, D. C. R., Rohayani, H., Suwanto, Arnita, Rico, Junaidi, R., Setyowati, R. D. N., Pramulya, R., & Setiawan, F. (2020). Weather Parameters

- Forecasting as Variables for Rainfall Prediction using Adaptive Neuro Fuzzy Inference System (ANFIS) and Support Vector Regression (SVR). *Journal of Physics: Conference Series*, 1501(1). <https://doi.org/10.1088/1742-6596/1501/1/012012>
- Putri, T. A. E., Widiharih, T., & Santoso, R. (2023). Penerapan Tuning Hyperparameter Randomsearchcv pada Adaptive Boosting untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung. *Jurnal Gaussian*, 11(3), 397–406. <https://doi.org/10.14710/j.gauss.11.3.397-406>
- Sušanj Čule, I., Ožanić, N., Volf, G., & Karleuša, B. (2025). Artificial Neural Network (ANN) Water-Level Prediction Model as a Tool for the Sustainable Management of the Vrana Lake (Croatia) Water Supply System. *Sustainability (Switzerland)*, 17(2). <https://doi.org/10.3390/su17020722>
- Xiong, Y. (2025). *Temperature and Humidity Prediction Based on Machine Learning*. 04004.
- Yakut, E., & Süzülmüş, S. (2020). Modelling monthly Mean Air Temperature Using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System And Support Vector Regression Methods: A Case Of Study For Turkey. *Network: Computation in Neural Systems*, 31(1–4), 1–36. <https://doi.org/10.1080/0954898X.2020.1759833>
- Zemnazi, O., Filali, S. El, & Ouahabi, S. (2024). Weather Forecasting Using Artificial Neural Network (ANN): A Review. *Procedia Computer Science*, 241, 618–623. <https://doi.org/10.1016/j.procs.2024.08.090>