

Prediksi Sensor Cuaca Menggunakan ANN Backpropagation: Studi Kasus Suhu, Kelembaban, dan Tekanan Udara

Sandi Ronggo Panji^{1,2, a)}, Agus Sofwan^{1, b)}

¹Program Studi S2 Teknik Elektro, Fakultas Teknik ISTN, Jakarta
Jl. Moh. Kahfi II, Jagakarsa, Jakarta Selatan, Indonesia 12640

²Direktorat Instrumentasi dan Kalibrasi, Badan Meteorologi Klimatologi dan Geofisika, Jakarta
16610, Indonesia

Email : ^{a)} sandi.panji@bmet.go.id, ^{b)} asofwan@istn.ac.id

Abstrak

Peralihan sistem pengamatan cuaca dari instrumen konvensional ke sensor digital menghadirkan tantangan besar terkait reliabilitas data, mengingat sensor rentan terhadap kerusakan teknis dan faktor lingkungan. Hilangnya data atau munculnya anomali sensor dapat mengganggu kualitas informasi meteorologi yang vital. Penelitian ini bertujuan merancang model prediksi nilai sensor berbasis Artificial Neural Network (ANN) dengan algoritma backpropagation, berfungsi sebagai sistem ganda untuk validasi dan imputasi data cuaca resolusi tinggi. Kami menggunakan data resolusi 1 menit selama satu tahun (Januari–Desember 2024) dari Stasiun Meteorologi Fatmawati Soekarno, Bengkulu, mencakup lebih dari 508 ribu data untuk suhu udara (T), kelembaban relatif (RH), dan tekanan udara (P). Model ANN diuji dengan arsitektur multilayer dan dievaluasi menggunakan R, RMSE, serta MAPE. Hasil menunjukkan bahwa model prediksi suhu udara (2-40-20-1) dan kelembaban udara (2-50-25-1) memberikan performa terbaik dengan $R > 0,91$ dan $MAPE < 5\%$, menandakan akurasi tinggi dalam menangkap pola non-linear cuaca mikro. Sebaliknya, prediksi tekanan udara menghasilkan korelasi lemah ($R=0,446$) meskipun nilai MAPE sangat kecil (0,132%), yang mencerminkan dominasi faktor atmosfer skala besar. Temuan ini menegaskan potensi ANN sebagai sistem ganda untuk deteksi anomali dan validasi data real-time, memperkuat integritas data pada operasional pengamatan cuaca digital.

Kata kunci: Artificial Neural Network, backpropagation, prediksi sensor cuaca, validasi data, resolusi tinggi.

Abstract

The transition from conventional weather observation instruments to digital sensors poses a significant challenge regarding data reliability, given that sensors are vulnerable to both technical failures and environmental factors. Missing data or the appearance of sensor anomalies can compromise the quality of meteorological information that is vital for climate analysis, weather forecasting, and disaster mitigation. This study aims to design a sensor value predictive model based on an Artificial Neural Network (ANN) with the backpropagation algorithm to support the validation and imputation of high-resolution weather data. The dataset was collected from the Fatmawati Soekarno Meteorological Station, Bengkulu, with a 1-minute resolution over the period of January–December 2024, yielding over 508,000 records for each parameter: air temperature (T), relative humidity (RH), and air pressure (P). The ANN model, featuring a multilayer architecture with two hidden layers, was tested across various neuron configurations and evaluated using the Correlation Coefficient (R), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the air temperature (architecture 2-40-20-1) and relative humidity (2-50-25-1) prediction models provided the best performance, achieving $R > 0.91$ and $MAPE < 5\%$. This demonstrates high accuracy and the ability to effectively capture non-linear micro-weather patterns. In contrast, air pressure prediction yielded a weak correlation ($R=0.446$), despite a very small MAPE (0.132%), reflecting the dominance of large-scale atmospheric factors. These findings highlight the potential of ANN not only as a predictive model for high-resolution weather sensors but also as a dual system for real-time anomaly detection and data validation. This research is expected to strengthen the transformation of digital weather observation toward a smarter, more adaptive, and reliable system.

Keywords: Artificial Neural Network, backpropagation, weather sensor prediction, data validation, high resolution.

1. Pendahuluan

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) telah beralih dari alat konvensional berbasis merkuri ke peralatan digital untuk pengamatan cuaca permukaan, sejalan dengan regulasi WMO tentang pelarangan merkuri dan alkohol (Furqon et al., 2021). Peralatan digital yang ditempatkan di taman alat meteorologi ini menggabungkan sensor otomatis dan estimasi manual, menawarkan efisiensi dan kontinuitas data, namun tetap rentan terhadap kerusakan fisik, kontaminasi, dan gangguan elektromagnetik (Suciarti et al., 2023).

Untuk mengatasi kendala tersebut, kecerdasan buatan (AI) menjadi solusi potensial karena kemampuannya menganalisis data besar dan mengenali pola kompleks (Bhargava & Sharma, 2021). Salah satu metode AI yang efektif untuk data non-linear cuaca adalah *Artificial Neural Network* (ANN) dengan

algoritma *backpropagation* (Heng et al., 2022; Zulfiani & Fauzi, 2023).

1.1. Penelitian Terkait

Metode *deep learning* berbasis *Artificial Neural Network* (ANN) dengan algoritma *backpropagation* banyak digunakan dalam prakiraan cuaca harian (Septiarini et al., 2022; Zulfiani & Fauzi, 2023), maupun prediksi unsur cuaca seperti radiasi matahari, suhu, dan jarak pandang (Duddu et al., 2020; Heng et al., 2022; Suciarti et al., 2023)

Algoritma *backpropagation* dimanfaatkan untuk memprediksi intensitas hujan di Lampung (Zulfiani & Fauzi, 2023), serta kondisi cuaca di Cilacap (Septiarini et al., 2022). Selain itu, metode ini juga terbukti efektif dalam memprediksi unsur cuaca lain seperti penyinaran matahari dan jarak pandang dengan input data suhu, kelembaban, kecepatan angin, dan radiasi global (Duddu et al., 2020; Heng et al., 2022).

Tabel 1. Penelitian Terkait

No.	Tujuan	Metode/Model	Variabel Input	Hasil Utama
1	Memprediksi radiasi matahari global (GSR) (Heng et al., 2022)	ANN (BR, LM, SCG)	Suhu, kelembaban, angin, radiasi (1985–2012)	BR terbaik, RMSE 0.8113
2	Memprediksi intensitas hujan harian (klasifikasi) (Zulfiani & Fauzi, 2023)	BPNN, SVM, LR	Tekanan, suhu, kelembaban, angin, hujan (2018–2022)	BPNN prediksi semua kelas; RMSE: ringan 0.68, sedang 0.17, lebat 0.03
3	Mengestimasi data suhu yang hilang pada AWS (Suciarti et al., 2023)	Hybrid ARIMA-MLP	Data 10-menit AWS (2019)	RMSE < 0,2°C, deteksi pola linear & non-linear
4	Menguji penerapan ANN Backpropagation untuk prediksi cuaca (Septiarini et al., 2022)	ANN-BP	Data harian BMKG Cilacap (2019–2021)	Arsitektur 4-10-2, LR 0.01, MAPE 2,568%
5	Memprediksi visibilitas (kondisi kabut) pada jalan (Duddu et al., 2020)	ANN-BP	Tutupan awan, elevasi, presipitasi, suhu, embun, angin, hujan (2010–2015, 238 lokasi)	BPNN terbaik untuk kabut normal, RMSE 0.73

Berdasarkan penelitian pada Tabel 1, belum ditemukan penerapan pendekatan multi-model yang digunakan sekaligus untuk prediksi dan validasi. Kontribusi penelitian ini ditawarkan sebagai berikut;
 1. Mengembangkan tiga model ANN yang saling berinteraksi, masing-masing

memprediksi satu variabel cuaca (suhu, kelembaban, tekanan) berdasarkan dua variabel lainnya,

- Model prediksi suhu udara dengan input kelembaban dan tekanan udara.

- Model prediksi kelembaban udara dengan input suhu dan tekanan udara.
 - Model tekanan udara dengan input suhu udara dan kelembaban udara.
2. Memanfaatkan data beresolusi sangat tinggi (1 menit) selama satu tahun untuk menangkap fluktuasi cuaca mikro yang tidak terdeteksi pada interval lebih besar.
 3. Menjadikan model prediksi sebagai sistem ganda untuk prediksi dan validasi, sehingga dapat mengimputasi data hilang sekaligus mendeteksi anomali sensor secara real time.

1.2. Hubungan Suhu, Kelembaban dan Tekanan Udara

Suhu udara (T), kelembaban relatif (RH), dan tekanan udara (P) saling terkait melalui tekanan uap aktual (e) dan tekanan uap jenuh (e_s), yang bergantung pada suhu, seperti pada Persamaan (1)

$$e = e_s(T) \cdot RH \quad (1)$$

Persamaan ini bersifat nonlinear, menunjukkan bahwa kapasitas udara menampung uap air meningkat eksponensial seiring kenaikan suhu. Jika RH tetap atau sedikit berubah, respons tekanan uap terhadap suhu mengikuti hubungan Clausius-Clapeyron dengan laju pertumbuhan $\pm 7\%/K$, terutama di lintang tinggi, di mana suhu menjadi faktor dominan dan kontribusi RH relatif kecil (Hao & Lu, 2022).

1.3. Deskripsi Studi Kasus


Peralihan dari peralatan cuaca konvensional ke sensor otomatis seperti AWS menghadapi tantangan berupa kerentanan sensor terhadap kerusakan yang memengaruhi akurasi data (Suciarti et al., 2023). Peralatan konvensional cenderung stabil, sedangkan sensor otomatis berpotensi mengalami malfungsi kompleks akibat faktor teknis maupun lingkungan.

Malfungsi pada sensor meliputi *bias fault* (penyimpangan konsisten akibat kalibrasi atau degradasi), *drift fault* (penyimpangan bertahap karena usia atau kontaminasi), *intermittent fault* (hilangnya data secara acak), dan *freezing fault* (sensor hanya menampilkan satu

nilai). Kerusakan ini sulit dideteksi dan dapat memberi kesan stabilitas palsu. Permasalahan tersebut berdampak serius karena menimbulkan *loss data* dan ketidakakuratan. Salah satu solusi yang banyak diteliti adalah pemanfaatan AI berbasis deep learning untuk mendeteksi dan mengatasi kelemahan sensor (Hasan et al., 2024; Taghezouit et al., 2024).

2. Metode Penelitian

Dalam penelitian ini, metode yang digunakan dalam pembuatan model menggunakan ANN dengan algoritma *backpropagation*. Adapun metode penelitian menggunakan alur sebagai berikut;



Gambar 1. Alur Penelitian

Gambar 1, merupakan alur penelitian yang berisi tahapan dalam penelitian, tahapannya meliputi: (1) studi literatur sebagai landasan teori, (2) pengumpulan data suhu, kelembaban, dan tekanan udara beresolusi 1 menit serta praproses untuk mengatasi data hilang atau anomali, (3) pembuatan model prediksi dengan pembagian data 80% untuk pelatihan dan 20% untuk validasi serta pengujian, (4) evaluasi kinerja model menggunakan metrik R, MAPE, dan RMSE, serta (5) penarikan kesimpulan mengenai efektivitas dan kelayakan model prediksi.

2.1 Lokasi Penelitian

Lokasi peralatan otomatis yang digunakan pada penelitian ini berada pada Stasiun Meteorologi Kelas III Fatmawati Soekarno, Kota Bengkulu. Pemilihan lokasi ini dikarenakan lokasi ini merupakan lokasi pemasangan baru yaitu pada desember 2024, sehingga dapat dipastikan kondisi peralatan otomatis berada pada kondisi yang baik dan baru.

2.2 Data Penelitian

Data diperoleh dari dashboard monitoring peralatan otomatis BMKG (<http://202.90.199.132/aws-new/>). Dashboard monitoring peralatan digital milik BMKG merupakan web monitoring yang berisi data dari peralatan otomatis. Adapun data yang akan digunakan berasal dari sensor Vaisala HMP155 untuk data suhu dan kelembaban udara serta Vaisala PTB330 untuk data tekanan udara



Gambar 2. Dashboard Monitoring Peralatan Otomatis BMKG
 (Sumber; Badan Meteorologi Klimatologi dan Geofisika)

Adapun data yang digunakan pada penelitian ini adalah seperti yang ditunjukkan pada tabel 2

Tabel 2. Data Penelitian

Uraian	Parameter Atmosfer		
	Suhu Udara (T) (°C)	Kelembaban Udara (RH) (%)	Tekanan Udara (P) (mb)
Jumlah data	507.527	507.527	507.527
Nilai Minimum	21,43	43,53	1000,70
Nilai maksimum	36,57	99,86	1013,20
Nilai rata-rata	27,94	82,71	1007,02

Tabel 2 memuat informasi data penelitian yang digunakan dalam rancangan model prediksi. Selanjutnya dibagi menjadi tiga bagian: *training*, *validation*, dan *testing*, sebagai bagian dari proses perancangan model, dengan proporsi seperti ditunjukkan pada tabel 3. dibawah ini;

Tabel 3. Pembagian Data Pembuatan Model Prediksi

Uraian	Jenis Data		
	Suhu Udara (T)	Kelembaban Udara (RH)	Tekanan Udara (P)
Data Training	406,022 (80%)	406.426 (80%)	406.426 (80%)
Data Validation	50,753 (10%)	50,753 (10%)	50,753 (10%)
Data Testing	50,753 (10%)	50,753 (10%)	50,753 (10%)

Pada tabel 2, memuat informasi jumlah data yang digunakan pada tahapan proses dalam pembuatan model prediksi.

2.3 Desain Model ANN

Model ANN yang digunakan memiliki arsitektur *multilayer* dengan dua *hidden layer* (Heng et al., 2022; Milstein & Blackwell, 2016). Komposisi *neuron* pada *hidden layer* seperti yang ditunjukkan pada table 4

Tabel 4. Desain Model Prediksi dengan ANN Algoritma Backpropagation

Sensor	Suhu (T)	Kelembaban (RH)	Tekanan (P)
Satuan	°C	%	mb
Arsitektur			
Hidden Layer 1	12 sampai 50 neuron (kelipatan 10)		
Hidden Layer 2	0,5 kali neuron Hidden Layer 1		
Epoch	1000	1000	1000
Fungsi Aktivasi	Sigmoid	Sigmoid	Sigmoid
Variabel input	RH+P	T+P	T+RH

Dari table 4, diketahui bahwa arsitektur menggunakan 2 *hidden layer* dengan komposisi *neuron*.

Untuk menjaga agar model yang dihasilkan tidak mengalami *overfitting* atau *underfitting*, yaitu keadaan dimana model tidak dapat melakukan interpretasi dalam proses pembelajaran model. Untuk mengatasi hal tersebut diperlukan penggunaan parameter pembelajaran (Aliferis & Simon, 2024; Liu et al., 2023). Adapun parameter yang digunakan seperti yang ditampilkan pada tabel 5.

Tabel 5. Parameter Pembelajaran untuk Model Prediksi

Parameter	Keterangan
Epochs = 1000	Jumlah maksimum epoch
Goal = 0.01	performansi (error) yang ingin dicapai.
Grad = 10^{-6}	Gradien performansi minimum.
Max_fail = 6	Jumlah maksimum kegagalan validasi

Tabel 5, merupakan parameter pembelajaran yang digunakan dengan penjelasan sebagai berikut;

1. *Epochs* merupakan jumlah siklus penuh yang melewati seluruh dataset. Pada penelitian ini digunakan maksimum 1000 siklus.
2. *Goal* digunakan untuk membatasi error yang diperkenankan, ditetapkan ≤ 0.01 . Jika tercapai, proses pembelajaran otomatis berhenti.
3. *Grad* atau *gradien performansi* merupakan ukuran perubahan bobot selama pelatihan. Nilai ditetapkan 10^{-6} , artinya pembaruan bobot $< 10^{-6}$ dianggap tidak bermakna.
4. *Max fail* merupakan batas kegagalan validasi, yaitu 6 kali berturut-turut. Jika tercapai, pelatihan dihentikan untuk mencegah model kehilangan kemampuan generalisasi dengan baik ke data baru selain itu *max fail* berfungsi agar proses dalam pembelajaran tidak terjadi *overfitting* dan *underfitting* (Aliferis & Simon, 2024; Liu et al., 2023).

Tiap model akan mendapatkan variable input yang berbeda seperti yang ditunjukkan pada tabel dibawah ini;

Tabel 6. Variabel input untuk tiap model prediksi

Model Prediksi	Parameter Atmosfer		
	T (°C)	RH (%)	P (mb)
Suhu Udara (T)		√	√
Kelembaban Udara (RH)	√		√
Tekanan Udara (P)	√	√	

Pada tabel 6, dijelaskan bahwa untuk menghasilkan model prediksi diperlukan input dari parameter lainnya.

2.4 Normalisasi Data

Pembacaan data untuk model prediksi T, RH, dan P mengikuti praktik standar machine learning dengan tahap normalisasi menggunakan Min-Max Scaling sehingga semua fitur berada pada rentang [0,1]. Normalisasi penting karena algoritma backpropagation sensitif terhadap perbedaan skala antar fitur. Tanpa normalisasi, fitur dengan nilai besar dapat mendominasi proses pembelajaran, memperlambat konvergensi, dan menurunkan stabilitas model ANN (Milligan et al., 2024; Saleh & Jawad, 2021; Sujon et al., 2024). Adapun persamaan yang digunakan pada metode *Min-Max Scaling* adalah sebagai berikut;

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

2.5 Evaluasi Model

Model yang digunakan perlu dilakukan evaluasi yang meliputi performa, akurasi dan *error*. Evaluasi model diperlukan untuk menilai performa, akurasi, dan error. Tiga parameter utama yang digunakan adalah koefisien korelasi (R), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) (Shishegaran et al., 2021), sebagai berikut;

$$R = \frac{\sum_{i=1}^m (x_i - \bar{x}) \sum_{i=1}^m (y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x})^2 \sum_{i=1}^m (y_i - \bar{y})^2}} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - x_i)^2} \quad (4)$$

$$MAPE = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{x_i - y_i}{y_i} \right| \quad (5)$$

Dimana; y adalah parameter output atau nilai prediksi yang dihasilkan, x adalah input parameter input dan m adalah banyaknya data.

Koefisien korelasi merupakan koefisien yang menyatakan hubungan antar variabel data prediksi terhadap data target dalam skala 0-1. RMSE merupakan matrik evaluasi yang digunakan untuk mengukur nilai *error* dimana nilai yang lebih rendah menunjukkan tingkat akurasi yang tinggi. MAPE menyatakan nilai error dalam bentuk persentase, nilai MAPE yang rendah menunjukkan tingkat akurasi yang

tinggi dalam prediksi (Latifoğlu & Özger, 2023; Ng et al., 2023).

Model terbaik dipilih berdasarkan kombinasi nilai R, RMSE dan MAPE rendah, serta harus bebas dari *overfitting* maupun *underfitting*.

3. Hasil dan Pembahasan

Penelitian ini membangun tiga model prediksi (T, RH, dan P) menggunakan *Artificial Neural Network* (ANN) dengan algoritma backpropagation. Setiap model memiliki arsitektur umum 2 *neuron input*, 2 *hidden layer*, dan 1 *neuron output*,

dengan variasi jumlah neuron pada hidden layer untuk memperoleh konfigurasi terbaik. Evaluasi dilakukan pada tiga fase (*training*, *validation*, *testing*) menggunakan tiga metrik utama: koefisien korelasi (R), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE)

3.1. Hasil Model Prediksi Suhu Udara (T)

Hasil pembelajaran model prediksi suhu udara (T) yang mencakup *fase training*, *validation* dan *testing* adalah seperti yang ditunjukkan pada tabel 7.

Tabel. 7 Hasil Pembelajaran Model Prediksi Suhu Udara (T)

Arsitektur	Trainning			Validation			Testing		
	R	RMSE	MAPE	R	RMSE	MAPE	R	RMSE	MAPE
2-10-5-1	0.881	1.396	3.901	0.880	1.410	3.932	0.881	1.400	3.912
2-20-10-1	0.912	1.380	4.075	0.911	1.389	4.114	0.911	1.389	4.103
2-30-15-1	0.887	1.436	4.094	0.887	1.433	4.069	0.887	1.432	4.085
2-40-20-1	0.915	1.198	3.363	0.915	1.206	3.371	0.914	1.198	3.361
2-50-25-1	0.897	1.335	3.835	0.896	1.348	3.885	0.896	1.343	3.858

Tabel 7, menyajikan hasil pembelajaran model prediksi suhu udara (T) dengan arsitektur berbeda, diperoleh sebagai berikut;

- (1) Keterkaitan dan Korelasi (R)
 Semua model memiliki $R > 0.880$, menunjukkan korelasi kuat antar prediksi dan data aktual. Model 2-40-20-1 memiliki R tertinggi (0.915 pada *training* dan *validation*), sehingga paling konsisten dalam memprediksi.
- (2) Tingkat Kesalahan (RMSE & MAPE)
 Nilai RMSE berkisar 1.198–1.436. Model 2-40-20-1 terbaik dengan RMSE 1.198. Semua model memiliki

MAPE < 5%, dengan model 2-40-20-1 terendah (3.363%).

- (3) Pemilihan Model Terbaik
 Berdasarkan hasil dari ketiga metrik, arsitektur 2-40-20-1 adalah model terbaik karena secara konsisten memiliki nilai R tertinggi serta nilai RMSE dan MAPE terendah di semua fase (*training*, *validation*, dan *testing*).

3.2. Hasil Model Prediksi Suhu Kelembaban Udara (RH)

Hasil pembelajaran model prediksi kelembaban udara (RH) seperti yang ditunjukkan pada tabel 8.

Tabel. 8 Hasil Pembelajaran Model Prediksi Kelembaban Udara (RH)

Arsitektur	Trainning			Validation			Testing		
	R	RMSE	MAPE	R	RMSE	MAPE	R	RMSE	MAPE
2-10-5-1	0.913	4.810	4.672	0.913	4.779	4.645	0.913	4.907	4.793
2-20-10-1	0.901	5.263	5.226	0.902	5.302	5.266	0.902	5.112	5.087
2-30-15-1	0.918	4.653	4.687	0.918	4.679	4.723	0.919	4.648	4.702
2-40-20-1	0.899	5.022	4.888	0.899	5.049	4.912	0.900	4.997	4.899
2-50-25-1	0.920	4.498	4.464	0.920	4.510	4.483	0.921	4.523	4.518

Tabel 8 menyajikan hasil pembelajaran dari lima arsitektur ANN untuk prediksi kelembaban udara (RH) pada fase *training, validation, dan testing* menggunakan metrik R, RMSE, dan MAPE sebagai berikut;

- (1) R (Koefisien Korelasi)
 Semua model memiliki $R > 0.900$, menunjukkan korelasi sangat kuat antara prediksi dan data aktual..
- (2) RMSE (*Root Mean Square Error*)
 Nilai RMSE berkisar antara 4.498 hingga 5.302. Nilai yang lebih rendah menunjukkan kesalahan prediksi yang lebih kecil.
- (3) MAPE (*Mean Absolute Percentage Error*)
 Nilai MAPE berkisar antara 4.464% hingga 5.266%. Semua nilai MAPE ini sangat baik karena berada di

bawah 10%, menunjukkan bahwa model memiliki akurasi yang tinggi.

- (4) Pemilihan Model Terbaik
 Berdasarkan hasil performa model diketahui bahwa semua model menunjukkan performa yang baik. Untuk model terbaik ditunjukkan oleh arsitektur 2-50-25-1 hal ini dikarenakan secara konsisten menghasilkan prediksi paling akurat dengan kesalahan paling kecil di semua fase pengujian.

3.3. Hasil Model Prediksi Tekanan Udara (P)

Hasil pembelajaran model prediksi Tekanan udara (P) yang mencakup fase *training, validation dan testing* adalah seperti yang ditunjukkan pada tabel 9.

Tabel. 9 Hasil Pembelajaran Model Prediksi Tekanan Udara (P)

Arsitektur	Trainning			Validation			Testing		
	R	RMSE	MAPE	R	RMSE	MAPE	R	RMSE	MAPE
2-10-5-1	0.408	1.673	0.133	0.406	1.670	0.133	0.413	1.685	0.135
2-20-10-1	0.424	1.660	0.132	0.420	1.658	0.132	0.430	1.671	0.133
2-30-15-1	0.432	1.653	0.131	0.428	1.651	0.131	0.437	1.664	0.133
2-40-20-1	0.430	1.655	0.132	0.426	1.653	0.132	0.435	1.666	0.133
2-50-25-1	0.445	1.642	0.130	0.439	1.642	0.130	0.446	1.656	0.132

Tabel 9 menyajikan hasil pembelajaran lima arsitektur ANN untuk prediksi tekanan udara (P), dievaluasi dengan R, RMSE, dan MAPE pada fase *training, validation, dan testing*. Berikut adalah interpretasi dari kinerja model tersebut;

- (1) Koefisien Korelasi (R)
 Nilai R untuk semua arsitektur berada di kisaran 0.408 hingga 0.446. Nilai ini menunjukkan korelasi yang lemah atau sedang antara nilai prediksi dan nilai aktual. Ini adalah indikasi bahwa model tidak terlalu efektif dalam menangkap hubungan linear antara *input* dan *output*.
- (2) RMSE (*Root Mean Square Error*)
 RMSE berada pada 1,642–1,685 mbar. Meski relatif kecil, rendahnya R memperlihatkan kecocokan model terhadap data masih terbatas..

- (3) MAPE (*Mean Absolute Percentage Error*)
 MAPE sangat rendah (0,130–0,135%), mengindikasikan kesalahan prediksi rata-rata kecil. Namun, nilai ini menyesatkan karena meskipun persentase error rendah, model tidak mengikuti pola data aktual dengan baik.

- (4) Berdasarkan hasil pembelajaran pada model prediksi tekanan udara (P) maka arsitektur 2-50-25-1 menunjukkan kinerja yang paling baik. Model arsitektur tersebut memiliki nilai R tertinggi (sekitar 0.44) dan nilai RMSE serta MAPE terendah (sekitar 1.64 dan 0.13%), secara konsisten di semua fase. Meskipun demikian, performa terbaik ini masih dianggap lemah karena nilai R yang jauh dari 1.0.

3.4. Pembahasan

Penerapan berbagai arsitektur ANN *backpropagation* dengan memperhatikan keterkaitan antara cuaca parameter menunjukkan bahwa setiap variabel cuaca memiliki kinerja prediksi yang berbeda, yang dipengaruhi oleh teori meteorologi dan rancangan jaringan yang digunakan.

3.4.1. Kinerja Model Prediksi

- (1) Arsitektur terbaik adalah 2-40-20-1 dengan $R=0,915$, $RMSE=1,198$, dan $MAPE=3,361\%$. Kinerja ini konsisten dengan teori Clausius–Clapeyron yang menjelaskan hubungan eksponensial antara suhu dan tekanan uap jenuh (Hao & Lu, 2022). Hal ini menunjukkan efektivitas ANN dalam memodelkan suhu dari input RH dan P.
- (2) Model Kelembaban Udara (RH) Model terbaik menggunakan arsitektur 2-50-25-1 dengan $R=0,921$, $RMSE=4,523$, dan $MAPE=4,518\%$. Hasil ini sejalan dengan teori keseimbangan energi dan dinamika kelembaban pada lapisan batas atmosfer, di mana kapasitas udara menampung uap

air meningkat dengan suhu (Lin et al., 2022; Yang et al., 2022). Model ANN terbukti mampu menangkap pola non-linear tersebut secara efektif.

- (3) Model Tekanan Udara (P) Prediksi tekanan udara menunjukkan korelasi lemah ($R=0,446$) dengan $RMSE=1,656$ meskipun $MAPE$ rendah ($0,132\%$). Rendahnya $MAPE$ dipengaruhi rentang variasi tekanan yang sempit. Sesuai teori meteorologi, tekanan udara lebih ditentukan faktor atmosfer skala besar seperti sistem sinoptik, konveksi, dan ENSO (Thuburn et al., 2022; Zhu et al., 2020). Dengan demikian, keterbatasan prediksi tekanan udara disebabkan oleh terbatasnya input lokal yang tidak mampu merepresentasikan dinamika atmosfer pada skala besar.

3.4.2. Perbandingan penelitian

Perbandingan penelitian ini dengan penelitian-penelitian sebelumnya yang digunakan sebagai penelitian terkait ditunjukkan pada tabel 10 dibawah ini

Tabel. 10 Perbandingan Hasil Penelitian

Studi Terdahulu	Fokus	Data & Resolusi	Hasil Utama	Perbandingan dengan Penelitian Ini
Heng et al., 2022	Radiasi matahari global	Harian	$RMSE=0,8113$	Studi ini lebih detail (1 menit), mampu tangkap pola mikro
Zulfiani & Fauzi, 2023	Intensitas hujan (klasifikasi)	Harian	BPNN unggul	Fokus studi ini regresi sensor (T, RH, P) resolusi menit
Suciarti et al., 2023	Estimasi suhu hilang AWS	10 menit	$RMSE < 0,2 \text{ } ^\circ\text{C}$	Studi ini ANN tunggal, $R > 0,9$ meski $RMSE \sim 1,2 \text{ } ^\circ\text{C}$ karena resolusi lebih detail
Septiarini et al., 2022	Prediksi cuaca harian (Cilacap)	Harian	$MAPE=2,568\%$	Studi ini $MAPE \sim 3-5\%$ tapi resolusi menit yang lebih fluktuatif
Duddu et al., 2020	Visibilitas (kabut)	Jam-an, multi lokasi	$RMSE=0,73$	Studi ini unggul temporal (1 menit, 1 lokasi) dibanding spasial

Tabel 10, merupakan tabel yang memberikan gambaran gap penelitian antara penelitian yang dilakukan dengan penelitian sebelumnya. Pada penelitian sebelumnya menunjukkan beragam penerapan ANN-BP. Heng et al. (2022) berhasil memprediksi radiasi matahari global ($RMSE=0,8113$) dengan resolusi harian. Zulfiani & Fauzi (2023)

menggunakan BPNN, SVM, dan LR untuk klasifikasi hujan harian, di mana BPNN paling unggul. Suciarti et al. (2023) mengestimasi data suhu hilang AWS dengan resolusi 10 menit menggunakan Hybrid ARIMA–MLP ($RMSE < 0,2 \text{ } ^\circ\text{C}$). Septiarini et al. (2022) memprediksi cuaca harian di Cilacap dengan ANN-BP ($MAPE=2,568\%$). Sementara itu, Duddu et

al. (2020) meneliti visibilitas kabut pada data jam-an dari 238 lokasi dengan RMSE 0,73.

Penelitian ini melengkapi studi terdahulu dengan resolusi lebih tinggi (1 menit), arsitektur ANN yang lebih dalam, dan fokus pada prediksi sensor suhu, kelembaban, serta tekanan udara. Hasil menunjukkan akurasi tinggi untuk suhu dan kelembaban ($R > 0,91$; $MAPE < 5\%$), meski prediksi tekanan masih terbatas.

4. Kesimpulan

Penelitian ini membuktikan efektivitas *Artificial Neural Network* (ANN) dengan backpropagation dan data resolusi tinggi (1 menit, Januari–Desember 2024) dalam mempelajari pola cuaca mikro sebagai berikut;

- (1) Akurasi Tinggi dan Keterkaitan Teoritis. Model ANN menunjukkan performa sangat baik untuk prediksi suhu (T) dan kelembaban relatif (RH), dengan $R > 0.91$ serta RMSE dan MAPE rendah. Hasil ini konsisten dengan teori meteorologi terkait hubungan non-linear antara suhu, kelembaban, dan tekanan uap jenuh.
- (2) Keterbatasan Variabel Sinoptik, pada model prediksi tekanan udara menghasilkan nilai $R=0.446$ meskipun nilai MAPE rendah. Kondisi ini menunjukkan pengaruh dominan faktor skala besar (sistem sinoptik, sirkulasi atmosfer) yang tidak sepenuhnya terwakili oleh input lokal (T dan RH).
- (3) Kontribusi Fungsional (Sistem Ganda), dibandingkan penelitian sebelumnya, model ini menggunakan arsitektur multi-layer lebih dalam dan berfungsi ganda sebagai validasi sensor real-time, imputasi data hilang, serta deteksi dini anomali sensor.

Hasil penelitian ini berimplikasi pada penguatan metode prediksi dan validasi sensor cuaca berbasis kecerdasan buatan dalam mendukung pemantauan kondisi sensor secara real-time. Untuk penelitian berikutnya, direkomendasikan integrasi variabel atmosfer skala makroskopis sebagai upaya peningkatan akurasi model prediksi tekanan udara.

Daftar Pustaka

- Abdulaal, A., Patel, A., Charani, E., Denny, S., Alqahtani, S. A., Davies, G. W., Mughal, N., & Moore, L. S. (2020). Comparison of deep learning with regression analysis in creating predictive models for SARS-CoV-2 outcomes. *BMC medical informatics and decision making*, 20(1), 299.
- Aliferis, C., & Simon, G. (2024). Overfitting, Underfitting and General Model Overconfidence and Under-Performance Pitfalls and Best Practices in Machine Learning and AI. In G. J. Simon & C. Aliferis (Eds.), *Artificial Intelligence and Machine Learning in Health Care and Medical Sciences: Best Practices and Pitfalls* (pp. 477-524). Springer International Publishing.
https://doi.org/10.1007/978-3-031-39355-6_10
- Bhargava, C., & Sharma, P. K. (2021). *Artificial intelligence: fundamentals and applications*. CRC Press.
- Duddu, V. R., Pulugurtha, S. S., Mane, A. S., & Godfrey, C. (2020). Back-propagation neural network model to predict visibility at a road link-level. *Transportation research interdisciplinary perspectives*, 8, 100250.
- Furqon, A., Putra, M., & Pramagusta, A. P. (2021). Implementasi Sistem Digitalisasi Pengamatan Cuaca di Stasiun Meteorologi Sultan Badaruddin II Palembang. Seminar Nasional Teknik Elektro,
- Hao, J., & Lu, E. (2022). Variation of relative humidity as seen through linking water vapor to air temperature: an assessment of interannual variations in the near-surface atmosphere. *Atmosphere*, 13(8), 1171.
- Hasan, M. N., Jan, S. U., & Koo, I. (2024). Sensor Fault Detection and Classification Using Multi-Step-Ahead Prediction with an Long Short-Term Memory (LSTM) Autoencoder. *Applied Sciences*, 14(17).

- Heng, S. Y., Ridwan, W. M., Kumar, P., Ahmed, A. N., Fai, C. M., Birima, A. H., & El-Shafie, A. (2022). Artificial neural network model with different backpropagation algorithms and meteorological data for solar radiation prediction. *Scientific reports*, *12*(1), 10457.
- Latifoğlu, L., & Özger, M. (2023). A novel approach for high-performance estimation of SPI data in drought prediction. *Sustainability*, *15*(19), 14046.
- Lin, J., Qian, T., Bechtold, P., Grell, G., Zhang, G. J., Zhu, P., Freitas, S. R., Barnes, H., & Han, J. (2022, 2022/08/08). Atmospheric Convection. *Atmosphere-Ocean*, *60*(3-4), 422-476.
<https://doi.org/10.1080/07055900.2022.2082915>
- Liu, Z., Xu, Z., Jin, J., Shen, Z., & Darrell, T. (2023). *Dropout Reduces Underfitting* Proceedings of the 40th International Conference on Machine Learning, Proceedings of Machine Learning Research.
<https://proceedings.mlr.press/v202/liu23aq.html>
- Milligan, A., Kunstner, F., Shirzad, H., Schmidt, M., & Sutherland, D. J. (2024). Normalization Matters for Optimization Performance on Graph Neural Networks. OPT 2024: Optimization for Machine Learning,
- Milstein, A. B., & Blackwell, W. J. (2016, 2016/02/27). Neural network temperature and moisture retrieval algorithm validation for AIRS/AMSU and CrIS/ATMS. *Journal of Geophysical Research: Atmospheres*, *121*(4), 1414-1430.
<https://doi.org/https://doi.org/10.1002/2015JD024008>
- Ng, J. L., Huang, Y. F., Chong, A. H., Lee, J. C., Abdulkareem, M., Md Noh, N. I. F., Mirzaei, M., & Ahmed, A. N. (2023). Comparative assessment of drought indices for evaluating drought patterns in Peninsular Malaysia. *Journal of Water and Climate Change*, *14*(11), 4183-4197.
- Saleh, R. A., & Jawad, H. T. (2021). The effect of some normalization methods on neural networks and robust methods with the presence of outliers.
- Septiarini, R. D., Istikaanah, N., & Sofiaty, N. (2022, 21 Desember 2022). APLIKASI MODEL ANN METODE BACKPROPAGATION UNTUK PREDIKSI CUACA DI KABUPATEN CILACAP. *Prosiding Seminar Nasional Matematika dan Terapannya (Senamantra) Vol. 3*, 285-296.
- Shishegaran, A., Varae, H., Rabczuk, T., & Shishegaran, G. (2021, 2021/04/15/). High correlated variables creator machine: Prediction of the compressive strength of concrete. *Computers & Structures*, *247*, 106479.
<https://doi.org/https://doi.org/10.1016/j.compstruc.2021.106479>
- Suciarti, S., Siregar, M. R., & Multi, A. (2023). Estimasi Sensor Temperatur Udara Automatic Weather Station Menggunakan Algoritma Hybrid Arima-MLP. *SAINSTECH: JURNAL PENELITIAN DAN PENGKAJIAN SAINS DAN TEKNOLOGI*, *33*(3).
- Sujon, K. M., Hassan, R. B., Towshi, Z. T., Othman, M. A., Samad, M. A., & Choi, K. (2024). When to use standardization and normalization: empirical evidence from machine learning models and XAI. *IEEE access*.
- Taghezouit, B., Harrou, F., Sun, Y., & Merrouche, W. (2024, 2024/03/01/). Model-based fault detection in photovoltaic systems: A comprehensive review and avenues for enhancement. *Results in Engineering*, *21*, 101835.
<https://doi.org/https://doi.org/10.1016/j.rineng.2024.101835>
- Thuburn, J., Efstathiou, G. A., & McIntyre, W. A. (2022). A two-fluid single-column model of turbulent shallow convection. Part 1: Turbulence equations in the multifluid framework. *Quarterly Journal of*

the Royal Meteorological Society,
148(748), 3366-3387.

- Yang, B., Wang, M., Zhang, G. J., Guo, Z., Wang, Y., Xu, X., Dai, G., Huang, A., Zhang, Y., & Qian, Y. (2022).** Parameterizing convective organization effects with a moisture-pdf approach in climate models: Concept and a regional case simulation. *Journal of Advances in Modeling Earth Systems*, 14(5), e2021MS002942.
- Zhu, A., Xu, H., Deng, J., Ma, J., & Li, S. (2020).** ENSO effect on interannual variability of Spring aerosols over East Asia. *Atmospheric Chemistry and Physics Discussions*, 2020, 1-32.
- Zulfiani, A., & Fauzi, C. (2023).** Penerapan Algoritma Backpropagation Untuk Prakiraan Cuaca Harian Dibandingkan Dengan Support Vector Machine dan Logistic Regression. *Jurnal Media Informatika Budidarma*, 7(3).