Prediksi Kondisi Cuaca Kota Pontianak Dengan Model Backpropagation Neural Network

Prediction of Weather Conditions in Pontianak City Using Backpropagation Neural Network Model

Albertus Duta Arya Bimo[1], Joko Sampurno[1]*, Andi Ihwan[1]

[1] Program Studi Geofisika, Jurusan Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Tanjungpura, Jl. Prof. Dr. H. Hadari Nawawi, Pontianak – Kalimantan Barat, Indonesia 78124

Email: aryabimo2003@gmail.com, *jokosampurno@physics.untan.ac.id, andiihwan@physics.untan.ac.id

Received: 02nd June 2026; Revised: 02nd July 2026; Accepted: 10th November 2026

Abstrak – *Kota Pontianak memiliki karakteristik cuaca khas wilayah khatulistiwa dengan intensitas hujan yang relatif tinggi sepanjang tahun. Kondisi ini menuntut adanya model klasifikasi cuaca yang andal untuk mendukung perencanaan dan mitigasi di berbagai sektor. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi performa Jaringan Saraf Tiruan (JST) dengan algoritma Backpropagation dalam melakukan klasifikasi cuaca biner, yaitu hujan dan tidak hujan, di Kota Pontianak. Data yang digunakan merupakan data historis cuaca periode 2019–2023 yang diperoleh dari BMKG Stasiun Meteorologi Maritim Pontianak, dengan parameter suhu udara, tekanan udara, kecepatan angin, dan titik embun. Normalisasi data menggunakan Standard Scaler, serta pembagian data menjadi data latih dan data uji dengan rasio 70:30. Untuk mengatasi ketidakseimbangan kelas, diterapkan metode Synthetic Minority Oversampling Technique (SMOTE) pada data latih. Model JST dibangun menggunakan MLP Classifier dan dilatih dengan algoritma Backpropagation. Evaluasi performa model dilakukan menggunakan metrik Accuracy Score dan Cohen's Kappa Score, serta analisis time series untuk melihat pola prediksi temporal. Hasil penelitian menunjukkan bahwa model mencapai akurasi sebesar 68,24% dan nilai Cohen's Kappa sebesar 0,23 yang termasuk dalam kategori fair agreement. Analisis time series menunjukkan model mampu menangkap pola musiman cuaca, namun masih memiliki kecenderungan over-prediction terhadap kondisi hujan. Secara keseluruhan, JST Backpropagation dapat digunakan untuk klasifikasi cuaca di Kota Pontianak dengan performa yang cukup baik, meskipun masih memerlukan pengembangan lebih lanjut.*

Kata kunci: *Jaringan saraf tiruan; backpropagation; Kota Pontianak; SMOTE; klasifikasi cuaca.*

Abstract – *Pontianak City has climatic characteristics typical of an equatorial region, with relatively high rainfall intensity throughout the year. These conditions require a reliable weather classification model to support planning and mitigation in various sectors. This study aims to implement and evaluate the performance of an Artificial Neural Network (ANN) using the Backpropagation algorithm for binary weather classification (rainy and non-rainy) in Pontianak City. The data used consist of historical weather records from 2019 to 2023 obtained from the BMKG Maritime Meteorological Station of Pontianak, including air temperature, air pressure, wind speed, and dew point. The research stages include data preprocessing, transformation of the target variable into binary classification, data normalization using the Standard Scaler, and data splitting into training and testing sets with a 70:30 ratio. To address class imbalance, the Synthetic Minority Over-sampling Technique (SMOTE) was applied to the training data. The ANN model was developed using the MLP Classifier and trained with the Backpropagation algorithm. Model performance was evaluated using the Accuracy Score and Cohen's Kappa Score, complemented by time series analysis. The results show that the model achieved an accuracy of 68.24% and a Cohen's Kappa value of 0.23 categorized as fair agreement. The model is able to capture seasonal weather patterns but still tends to over-predict rainy conditions. Overall, the ANN with Backpropagation demonstrates*

adequate performance for weather classification in Pontianak City, although further improvements are required.

Keywords: *Artificial neural network; backpropagation; Pontianak City; SMOTE; weather classification.*

1. Pendahuluan

Kota Pontianak merupakan ibu kota Provinsi Kalimantan Barat, dikenal dengan julukan Kota Khatulistiwa karena lokasinya yang berada tepat di garis khatulistiwa. Kota ini memiliki dua musim utama, yaitu musim hujan dan musim kemarau, yang dipengaruhi oleh curah hujan [1]. Cuaca di Pontianak ditandai dengan suhu yang tinggi serta curah hujan yang sering terjadi sepanjang tahun.

Studi terbaru menunjukkan adanya peningkatan suhu permukaan di Pontianak, dengan rata-rata suhu mencapai 30,8 °C pada periode 2013–2019. Peningkatan ini kemungkinan disebabkan oleh faktor urbanisasi dan berkurangnya vegetasi di wilayah perkotaan [2]. Selain itu, indikator perubahan iklim di Pontianak juga dapat diamati melalui perubahan durasi sinar matahari serta kisaran suhu diurnal. Penelitian lebih lanjut mengungkapkan bahwa suhu minimum di Pontianak meningkat lebih cepat dibandingkan suhu maksimum, yang mengindikasikan adanya perubahan pola iklim di daerah tersebut [3].

Salah satu pendekatan yang digunakan dalam memprediksi cuaca adalah menggunakan metode jaringan syaraf tiruan (JST). JST sangat sesuai untuk prediksi cuaca karena kemampuannya dalam memodelkan hubungan *non-linear* yang kompleks antara berbagai variabel meteorologi. Data cuaca bersifat dinamis dan stokastik, di mana perubahan satu variabel dapat mempengaruhi variabel lain dengan cara yang tidak dapat di jelaskan oleh model statistik linear konvensional [4]. Dengan kemampuannya dalam memproses data dalam jumlah besar dari berbagai sumber, seperti satelit, radar, dan stasiun cuaca, JST dapat menghasilkan prediksi yang lebih akurat. Selain itu, metode ini mampu melakukan pembelajaran mandiri (*self-learning*), menyesuaikan parameter prediksi berdasarkan perubahan pola cuaca, serta memiliki ketahanan terhadap data yang tidak lengkap atau bervariasi.

Fleksibilitas JST dalam menangani berbagai variabel cuaca, seperti suhu, curah hujan, kelembapan, dan tekanan udara, menjadikannya metode yang adaptif dan efisien. Dengan perangkat komputasi JST semakin unggul dalam memproses data deret waktu yang krusial untuk prediksi cuaca. JST dengan algoritma *Backpropagation* telah berhasil diterapkan untuk prediksi curah hujan di berbagai daerah, seperti Wonosobo dan Sumatera Utara, dengan tingkat akurasi yang tinggi [5]. Keunggulan JST terletak pada kemampuannya untuk memproses data historis cuaca, termasuk suhu, kelembaban, dan tekanan udara, untuk menghasilkan prediksi yang akurat [4]. Optimasi arsitektur jaringan dapat meningkatkan efisiensi tanpa mengorbankan akurasi secara signifikan [4]. Meskipun memerlukan data pelatihan yang memadai, JST terbukti efektif dalam memprediksi curah hujan, dengan potensi aplikasi yang luas di berbagai sektor seperti pertanian dan mitigasi bencana.

Beberapa penelitian sebelumnya telah menerapkan JST untuk prediksi curah hujan di berbagai wilayah, termasuk di Kota Pontianak. Rachmawati [4] memprediksi curah hujan Kota Pontianak pada skala bulanan, dasarian, dan harian menggunakan parameter cuaca sebagai prediktor, sementara Manalu [5] menerapkan JST *Backpropagation* untuk prediksi curah hujan di Sumatera Utara. Kedua penelitian tersebut, sebagaimana juga penelitian JST cuaca lain di Pontianak [6], umumnya belum secara eksplisit menangani permasalahan ketidakseimbangan kelas (*class imbalance*) antara kejadian hujan dan tidak hujan, padahal proporsi kejadian hujan harian di wilayah tropis khatulistiwa seperti Pontianak cenderung lebih kecil dibandingkan hari tidak hujan, sehingga berpotensi menyebabkan model bias terhadap kelas mayoritas apabila tidak ditangani secara khusus. Oleh karena itu, kebaruan (novelty) penelitian ini terletak pada penerapan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) untuk mengatasi ketidakseimbangan kelas pada data cuaca biner Kota Pontianak, yang dikombinasikan dengan evaluasi model secara komprehensif menggunakan metrik *Accuracy Score* dan *Cohen's Kappa Score* serta analisis time series untuk menilai konsistensi pola prediksi musiman terhadap data observasi. Pendekatan gabungan ini belum banyak diterapkan pada studi klasifikasi cuaca biner di wilayah khatulistiwa, sehingga penelitian ini diharapkan dapat mengisi celah penelitian (*research gap*) tersebut.

Berdasarkan celah penelitian tersebut, pada penelitian ini, metode JST dengan algoritma Backpropagation diimplementasikan untuk memprediksi kondisi cuaca di Kota Pontianak. Data yang

digunakan mencakup parameter meteorologi seperti suhu udara, kecepatan angin, titik embun, dan tekanan udara, yang diperoleh dari Badan Meteorologi Krimatologi dan Geofisika (BMKG) Stasiun Maritim Pontianak. Proses pelatihan model dilakukan dengan mengoptimalkan parameter seperti jumlah neuron tersembunyi, fungsi aktivasi, dan tingkat pembelajaran untuk mendapatkan hasil terbaik. Hasil penelitian ini diharapkan dapat memberikan prediksi cuaca yang lebih akurat, sehingga dapat digunakan sebagai referensi dalam perencanaan mitigasi bencana, pengelolaan sumber daya air, serta sektor pertanian dan transportasi di Kota Pontianak.

2. Material dan Metode

2.1. Pengumpulan dan pra-pemrosesan data

Penelitian dilakukan di BMKG Stasiun Meteorologi Maritim Pontianak yang berlokasi di Kota Pontianak, Kalimantan Barat. Secara geografis, lokasi penelitian berada pada koordinat 0°1'22.0" LS dan 109°20'24.2" BT, dengan periode data harian dari Januari 2019 hingga Desember 2023 (5 tahun), seperti yang ditampilkan pada Gambar 1.

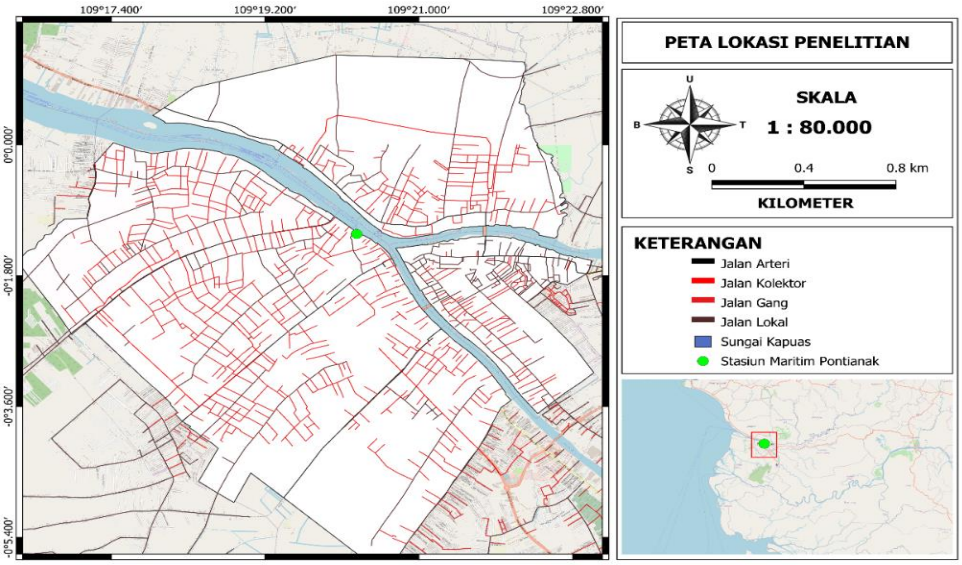

GaProofreadingmbar 1. Peta lokasi penelitian.

Tahapan pra-pemrosesan diawali dengan melakukan transformasi biner pada variabel target, di mana kondisi cuaca dikategorikan menjadi nilai 0 untuk kondisi "Tidak Hujan" dan nilai 1 untuk kondisi "Hujan" guna menyederhanakan kompleksitas klasifikasi. Selanjutnya, dilakukan normalisasi data menggunakan metode *Standard Scaler* terhadap fitur-fitur meteorologi yang meliputi suhu udara, tekanan udara, kecepatan angin, dan titik embun. Proses ini bertujuan untuk menyamakan skala antar variabel dengan mengubah nilai rata-rata menjadi 0 dan standar deviasi menjadi 1, sehingga mencegah dominasi fitur dengan rentang nilai yang lebih besar dalam proses pembelajaran model. Untuk mengatasi masalah ketidakseimbangan kelas (*class imbalance*) pada dataset, teknik SMOTE diterapkan secara khusus pada data latih. Teknik ini bekerja dengan menghasilkan sampel sintetis pada kelas minoritas sehingga model dapat mempelajari karakteristik hujan secara lebih representatif dan tidak hanya cenderung memprediksi kelas mayoritas.

2.2. Arsitektur Model JST

Jaringan saraf tiruan (JST) merupakan salah satu cabang dari kecerdasan buatan (*artificial intelligence*) yang dirancang untuk meniru cara kerja sistem saraf biologis manusia, khususnya pada kemampuan otak untuk belajar dari pengalaman dan mengenali pola [6]. JST bekerja dengan cara memproses informasi melalui sekumpulan elemen pemrosesan sederhana yang disebut *neuron* atau *node* [7]. Keunggulan utama dari teknologi ini adalah kemampuannya untuk menyelesaikan permasalahan yang bersifat *non-linear* dan

stokastik, dimana hubungan antara variabel *input* dan *output* tidak dapat dijelaskan dengan rumus matematika sederhana [8].

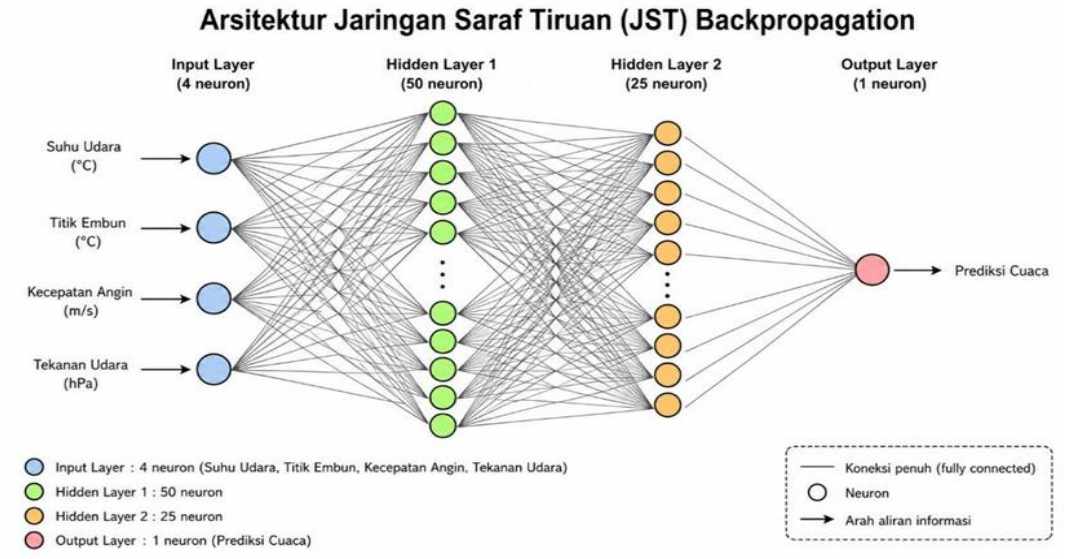

Gambar 2. Arsitektur Model Jaringan Saraf Tiruan 4 *input*, 2 *hidden layer* dan 1 *output*.

Seperti pada Gambar 2 model jaringan saraf tiruan menggunakan arsitektur *Multi-Layer Perceptron* (MLP) dengan struktur yang terdiri dari satu lapisan input, dua lapisan tersembunyi (*hidden layers*), dan satu lapisan *output*. Lapisan input menampung empat *neuron*. Model Jaringan Saraf Tiruan yang dikembangkan menggunakan arsitektur MLP dengan struktur yang terdiri dari satu lapisan *input*, dua lapisan tersembunyi, dan satu lapisan *output*. Lapisan *input* menampung empat *neuron* yang merepresentasikan masing-masing parameter meteorologi, sementara lapisan tersembunyi pertama terdiri dari 50 *neuron* dan lapisan kedua terdiri dari 25 *neuron* untuk menangkap pola fitur yang lebih mendalam. Fungsi aktivasi ReLU (*Rectified Linear Unit*) diterapkan pada lapisan tersembunyi untuk mengatasi masalah vanishing gradient dan mempercepat konvergensi selama proses pelatihan [9]. Pada lapisan *output*, digunakan fungsi aktivasi Sigmoid untuk menghasilkan probabilitas klasifikasi biner. Proses optimasi bobot dilakukan menggunakan algoritma Adam (*Adaptive Moment Estimation*) yang dikenal efisien dalam menangani *dataset* besar dan memiliki laju pembelajaran yang adaptif [6]. Pada proses pelatihan, bobot jaringan disesuaikan secara berulang melalui algoritma *backpropagation* untuk meminimalkan selisih antara keluaran aktual dan keluaran yang diinginkan [10]. Secara teoretis, jaringan umpan-maju berlapis jamak dengan jumlah *neuron* tersembunyi yang memadai mampu mengaproksimasi fungsi non-linear kontinu dengan ketelitian yang diinginkan [11]. *Standard Scaler* dan *MLP Classifier* yang digunakan dalam penelitian ini tersedia pada pustaka *scikit-learn* [12].

2.3. Matriks evaluasi performa model

Evaluasi terhadap kemampuan generalisasi model dilakukan menggunakan pembagian data secara acak dengan proporsi 70% sebagai data latih dan 30% sebagai data uji. Metrik evaluasi utama yang digunakan dalam penelitian ini meliputi *Accuracy Score* untuk mengukur presentase prediksi yang tepat secara keseluruhan dan *Cohen's Kappa Score* untuk mengevaluasi tingkat kesepakatan antara hasil prediksi model dengan observasi aktual secara lebih objektif, terutama dalam menghadapi dataset yang telah diseimbangkan [4]. *Cohen's Kappa* pertama kali diperkenalkan sebagai koefisien kesepakatan untuk skala nominal yang mengoreksi kesepakatan yang terjadi secara kebetulan [13], namun perilakunya dapat menyimpang pada kondisi distribusi kelas yang tidak seimbang [14], sehingga dalam penelitian ini nilai Kappa dilaporkan bersama *accuracy* dan *confusion matrix*. Rumus untuk menghitung *accuracy* diperlihatkan pada Persamaan (1).

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Keterangan:
TP (*True Positive*): jumlah kejadian hujan (aktual) yang diprediksi secara benar sebagai hujan.
TN (*True Negative*): jumlah kejadian tidak hujan (aktual) yang diprediksi secara benar sebagai tidak hujan.
FP (*False Positive*): jumlah kejadian tidak hujan (aktual) yang keliru diprediksi sebagai hujan.
FN (*False Negative*): jumlah kejadian hujan (aktual) yang keliru diprediksi sebagai tidak hujan.

Selanjutnya, rumus untuk menghitung *Cohen's Kappa Score* diperlihatkan pada Persamaan (2).

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (2)$$

Dimana:

$$P_o = \frac{(TP+TN)}{N}$$

$$P_e = \frac{[(TP + FN)\, x\, (TP + FP) + (FP + TN)\ \times\ (FN + TN)]}{N^2}$$

P_o menyatakan proporsi kesepakatan yang teramati (*observed agreement*) antara hasil prediksi model dan data aktual, yaitu proporsi jumlah prediksi yang benar ($TP+TN$) terhadap keseluruhan data ($N = TP + TN + FP + FN$). *Pe* menyatakan proporsi kesepakatan yang diharapkan terjadi secara kebetulan (*expected agreement by chance*), yang dihitung berdasarkan distribusi marginal antara data aktual dan data hasil prediksi untuk masing-masing kelas. Selain evaluasi statistik, dilakukan pula analisis data berkala (*time series*) menggunakan teknik *Moving Average* untuk membandingkan tren frekuensi kejadian hujan hasil prediksi terhadap data observasi asli guna memvalidasi kemampuan model dalam mengikuti pola musiman di Kota Pontianak.

3. Hasil dan Pembahasan

3.1. Evaluasi performa model

Performa model *Backpropagation Neural Network* dievaluasi menggunakan metrik *accuracy* dan *Cohen's Kappa*, mengacu pada pendekatan yang digunakan oleh [5]. Tingkat keandalan prediksi ditentukan berdasarkan skala interpretasi nilai akurasi [5] dan nilai Kappa [6], sebagaimana disajikan pada Tabel 1 dan 2. Pengelompokan nilai Kappa pada Tabel 2 sejalan dengan skala interpretasi yang dikemukakan oleh Landis dan Koch [15].

Tabel 1. Skala interpretasi *accuracy* [5].

No	Nilai *Accuracy*	Tingkat Kinerja
1	> 90%	Sangat baik
2	80% - 90 %	Baik
3	70% - 80%	Cukup
4	< 70 %	Kurang baik

Tabel 2. Skala interpretasi Nilai *Kappa Coefficient* [6].

No	Nilai Kappa (κ)	Tingkat Persetujuan
1	< 0	Buruk
2	0.00 - 0.20	Ringan
3	0.21 - 0.40	Cukup
4	0.41 - 0.60	Sedang
5	0.61 - 0.80	Substansial
6	0.81 - 1.00	Hampir sempurna

Sebagai gambaran umum, evaluasi akhir model pada penelitian ini menggunakan 4.383 data uji harian (30% dari total data yang telah melalui tahap pra-pemrosesan pada Subbab 2.1), dengan empat variabel prediktor meteorologi (suhu udara, tekanan udara, kecepatan angin, dan titik embun) serta satu variabel target biner (0 = Tidak Hujan, 1 = Hujan). Selain metrik akurasi dan Kappa, performa model juga dianalisis melalui kurva loss pada Gambar 3 dan *confusion matrix* pada Gambar 4.

Kurva loss (Gambar 3) menunjukkan proses konvergensi model selama 1000 epoch. Untuk mengoptimalkan durasi pelatihan dan mencegah terjadinya *overfitting*, penelitian ini menerapkan mekanisme *early stopping*. Terlihat bahwa loss pada data latih dan data validasi menurun secara konsisten dan stabil, yang mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan dan berhasil mencapai titik konvergensi yang optimal.

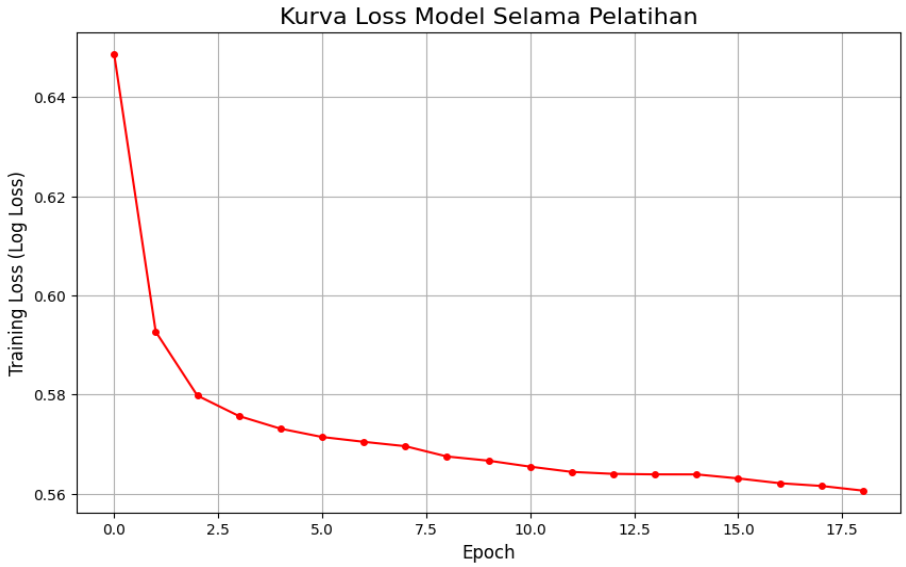

Gambar 3. Grafik Kurva Loss Model Selama Pelatihan.

Berdasarkan *confusion matrix* pada Gambar 4 (Data Uji), dari total 4.383 data uji, model berhasil mengklasifikasikan dengan benar 2.515 data sebagai 'Tidak Hujan' (*True Negative*) dan 476 data sebagai 'Hujan' (*True Positive*). Model keliru memprediksi 1.163 data 'Tidak Hujan' aktual sebagai 'Hujan' (*False Positive*), serta 229 data 'Hujan' aktual sebagai 'Tidak Hujan' (*False Negative*). Berdasarkan angka tersebut, model memperoleh nilai *accuracy* sebesar 0,6824 (68,24%) dan *Cohen's Kappa* sebesar 0,23. Mengacu pada Tabel 1, nilai akurasi 68,24% berada di bawah ambang 70% sehingga tergolong kategori "kurang baik", sedangkan mengacu pada Tabel 2, nilai Kappa 0,23 berada pada rentang 0,21–0,40 yang tergolong kategori "cukup" (*fair agreement*). Kedua metrik ini saling melengkapi: akurasi keseluruhan belum optimal, namun tingkat kesepakatan antara prediksi dan observasi aktual, setelah memperhitungkan kemungkinan kesepakatan acak, masih berada pada kategori yang dapat diterima.

Jika ditinjau lebih rinci, sensitivitas model dalam mendeteksi kejadian hujan (*recall* kelas Hujan) adalah 476/(476+229) = 67,5%, sementara spesifisitas model dalam mendeteksi kejadian tidak hujan adalah 2.515/(2.515+1.163) = 68,4%. Nilai presisi kelas Hujan tergolong rendah, yaitu 476/(476+1.163) = 29,0%, yang berarti dari seluruh prediksi 'Hujan' yang dikeluarkan model, hanya sekitar 29% yang benar-benar terjadi hujan. Hasil ini menunjukkan bahwa performa model belum optimal secara merata pada kedua kelas. Beberapa faktor yang diduga berkontribusi terhadap performa yang belum optimal ini antara lain: (1) keterbatasan jumlah variabel prediktor yang digunakan (hanya empat parameter meteorologi permukaan), sementara kejadian hujan konvektif di wilayah khatulistiwa juga dipengaruhi oleh faktor atmosfer lain seperti kelembapan relatif, tutupan awan, dan pola sirkulasi regional yang belum dilibatkan dalam model; (2) resolusi temporal data harian yang mungkin kurang mampu menangkap dinamika hujan konvektif yang bersifat lokal dan berdurasi pendek; serta (3) penerapan SMOTE pada data latih yang, meskipun efektif menyeimbangkan proporsi kelas, berpotensi menghasilkan sampel sintetis yang tidak

sepenuhnya merepresentasikan variabilitas kondisi atmosfer riil sehingga memengaruhi generalisasi model pada data uji. Kemungkinan ini sejalan dengan cara kerja SMOTE yang membangkitkan sampel sintetis melalui interpolasi linear antara sampel kelas minoritas dan tetangga terdekatnya [16], sehingga distribusi sampel sintetis tidak selalu sesuai dengan distribusi asli kelas minoritas [17].

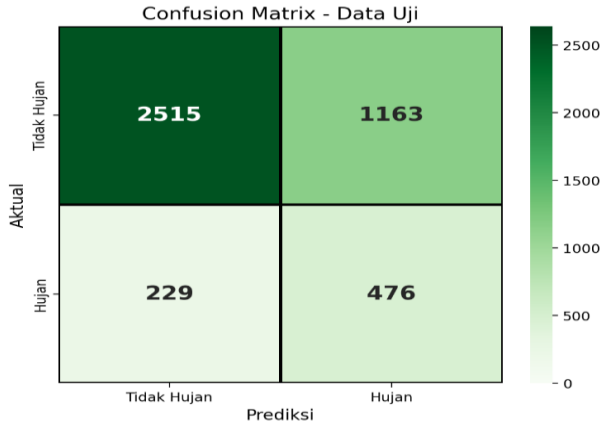

Gambar 4. *Confusion Matrix* Data Uji.

Ditinjau dari sisi dampak praktis, tingginya angka *false positive* (1.163 data) mengindikasikan potensi alarm palsu (*false alarm*) yang cukup signifikan apabila model diterapkan pada sistem peringatan dini cuaca, karena pengguna dapat menerima peringatan hujan pada kondisi yang sebenarnya tidak terjadi presipitasi. Di sisi lain, angka *false negative* (229 data) yang jauh lebih kecil dibandingkan *false positive* menunjukkan bahwa model relatif jarang melewatkan kejadian hujan aktual, karakteristik yang menguntungkan untuk tujuan kesiapsiagaan bencana, meskipun konsekuensi *false alarm* yang berulang tetap perlu diantisipasi agar tidak menurunkan kepercayaan pengguna terhadap sistem peringatan. Pendekatan JST untuk menghasilkan keluaran berupa probabilitas hujan telah lama dikembangkan, misalnya untuk prakiraan peluang presipitasi (*probability of precipitation*) di wilayah Dallas–Fort Worth, Amerika Serikat [18]. Oleh karena itu, pengembangan lanjutan dapat mempertimbangkan keluaran berbentuk probabilitas beserta penyesuaian ambang keputusan untuk menyeimbangkan *false alarm* dan kejadian hujan yang terlewat.

3.2. Analisis data time series

Analisis selanjutnya dilakukan dengan meninjau pergerakan data hasil prediksi model terhadap data aktual secara kronologis. Untuk mempermudah identifikasi tren, data harian diolah menggunakan teknik *Moving Average* periode 30 hari guna mereduksi fluktuasi harian yang ekstrem. Berdasarkan perbandingan tren yang disajikan pada Gambar 5. Terlihat bahwa model JST *Backpropagation* mampu menangkap pola musiman yang terjadi di Kota Pontianak, di mana terjadi kesesuaian antara kenaikan dan penurunan frekuensi hujan pada periode waktu tertentu. Namun, pengamatan lebih mendalam menunjukkan adanya fenomena *over-prediction* yang konsisten di sepanjang periode pengujian, dengan kurva prediksi model secara sistematis berada di atas kurva observasi aktual. Kecenderungan ini diduga dipengaruhi oleh penerapan metode SMOTE pada tahap pra-pemrosesan data, yang menyeimbangkan jumlah sampel kelas 'Hujan' secara artifisial sehingga kemungkinan berkaitan dengan ambang batas keputusan (*decision boundary*) model yang menjadi lebih sensitif terhadap indikasi hujan. Meskipun demikian, hubungan sebab-akibat tersebut belum dapat dipastikan sepenuhnya berdasarkan data yang tersedia dan memerlukan kajian lebih lanjut, misalnya melalui perbandingan performa model yang dilatih dengan dan tanpa SMOTE.

Secara meteorologis, kondisi Kota Pontianak yang berada di garis khatulistiwa umumnya dicirikan oleh kelembapan udara yang tinggi dan titik embun yang mendekati suhu udara, sehingga kondisi atmosfer yang mendekati titik jenuh berpotensi diinterpretasikan oleh model sebagai indikasi kejadian hujan meskipun presipitasi belum tentu terjadi. Namun, pernyataan ini masih bersifat dugaan awal (hipotesis), karena penelitian ini belum menyertakan data kelembapan relatif secara eksplisit sebagai variabel prediktor maupun analisis statistik yang secara langsung menghubungkan titik embun dengan pola *over-prediction*.

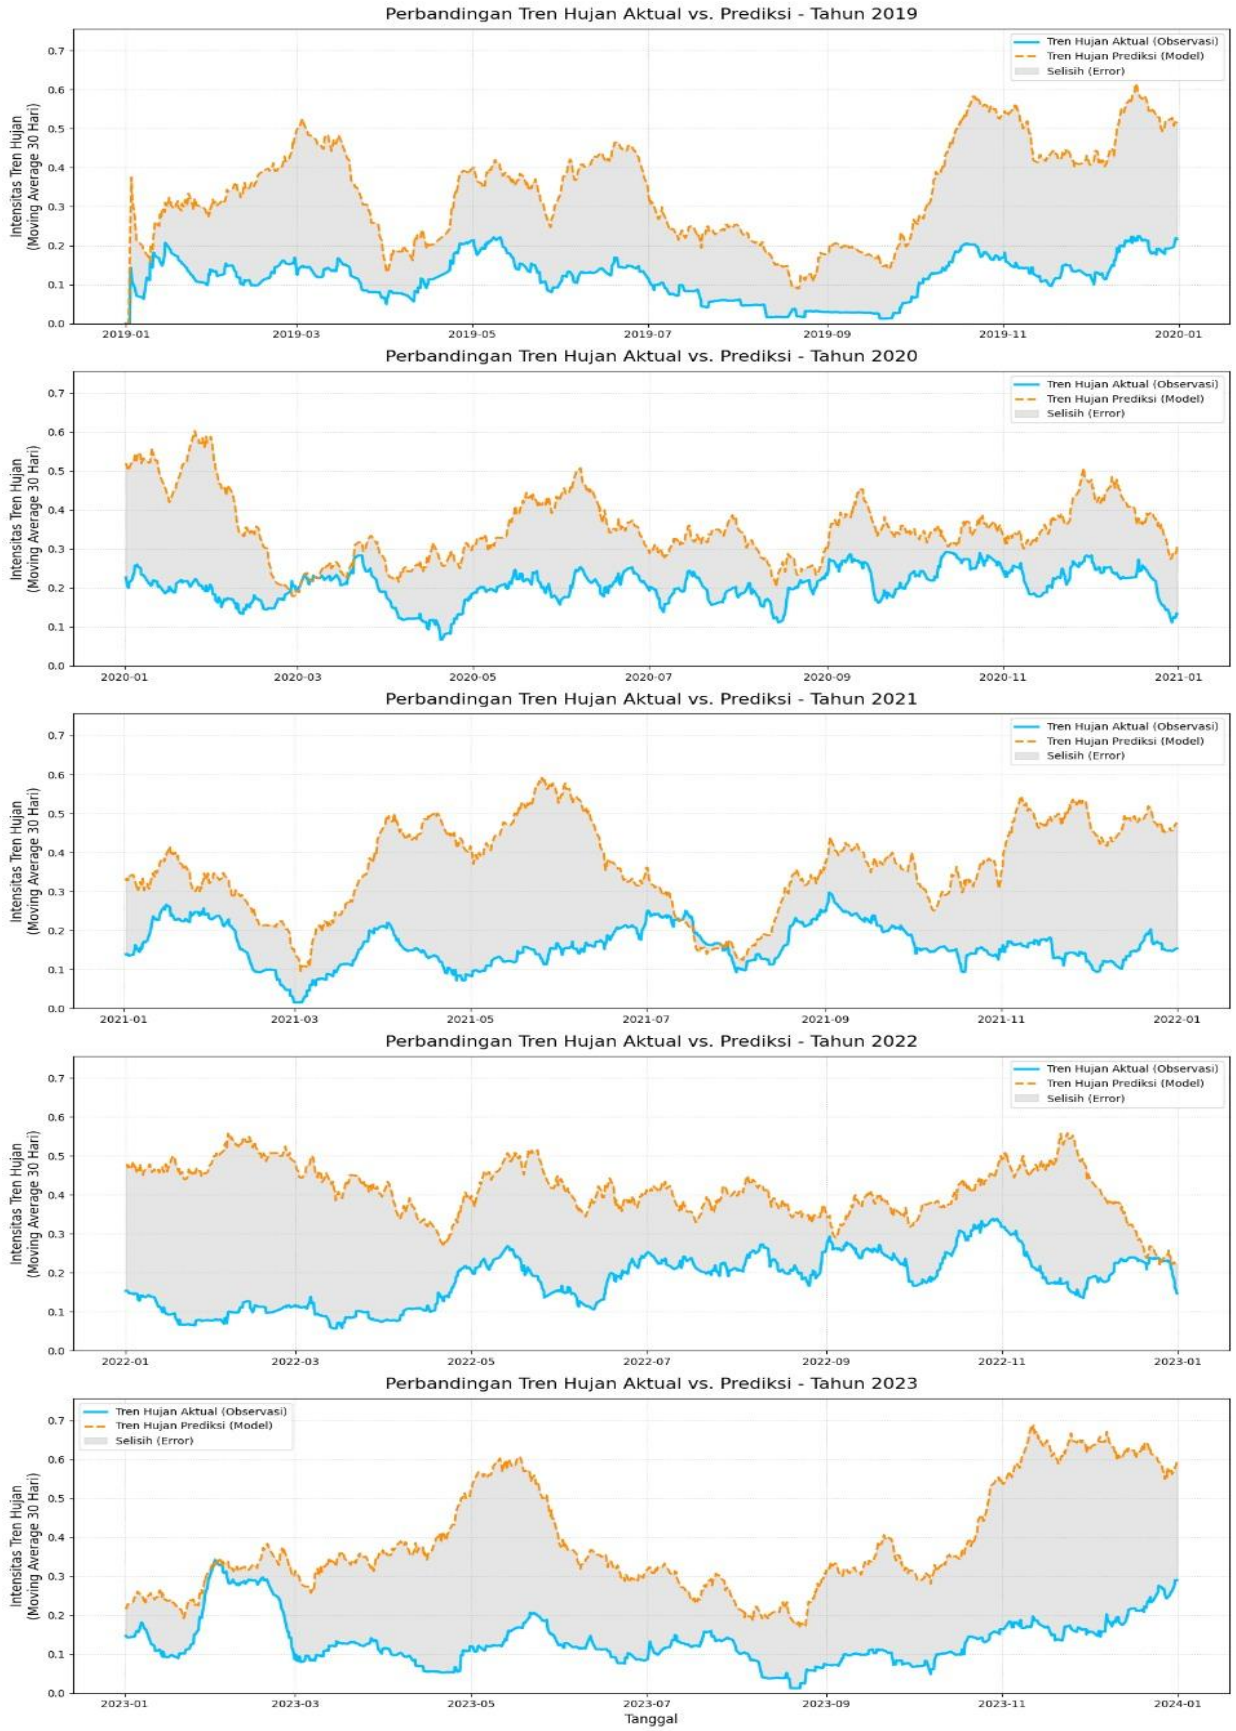

Gambar 5. Grafik *Time Series* Data Prediksi vs Observasi.

Verifikasi lebih lanjut menggunakan data kelembapan lokal dan analisis korelasi diperlukan pada penelitian selanjutnya untuk mengonfirmasi hipotesis ini. Berkaitan dengan implikasi praktis atas pola ini, sebagaimana telah dibahas pada Subbab 3.1, tingginya angka *false positive* berpotensi menimbulkan alarm palsu apabila model diterapkan pada sistem peringatan dini, sehingga aspek ini perlu menjadi perhatian utama dalam pengembangan model lanjutan. Di samping itu, curah hujan di Indonesia memiliki variabilitas musiman dan antartahunan yang dipengaruhi oleh monsun serta fenomena *El Niño–Southern Oscillation* (ENSO) dengan karakteristik yang berbeda antarwilayah [19], sehingga model yang hanya memanfaatkan empat variabel permukaan berpotensi belum menangkap seluruh faktor pengendali hujan harian di Pontianak.

4. Kesimpulan

Implementasi model Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation* telah berhasil diterapkan untuk klasifikasi cuaca biner (Hujan/Tidak Hujan) di Kota Pontianak menggunakan data historis harian periode Januari 2019–Desember 2023. Model yang dihasilkan memperoleh nilai akurasi sebesar 68,24% dan *Cohen's Kappa Score* sebesar 0,23. Berdasarkan skala interpretasi yang digunakan (Tabel 1 dan 2), nilai akurasi tersebut berada di bawah ambang 70% sehingga tergolong kategori "kurang baik", sedangkan nilai Kappa tergolong kategori "cukup" (*fair agreement*). Dengan demikian, meskipun model mampu menangkap pola musiman hujan dengan cukup baik pada analisis time series, tingkat akurasi klasifikasi biner secara keseluruhan masih belum optimal dan perlu ditafsirkan secara hati-hati. Penelitian ini menunjukkan bahwa algoritma *Backpropagation* merupakan metode yang fungsional untuk pemodelan awal klasifikasi cuaca di Kota Pontianak, namun performanya masih dibatasi oleh sejumlah faktor, antara lain keterbatasan variabel prediktor, resolusi temporal data harian, serta karakteristik data sintetis hasil SMOTE yang belum tentu merepresentasikan variabilitas atmosfer secara utuh. Untuk penelitian selanjutnya, disarankan beberapa langkah pengembangan yang lebih spesifik, yaitu: (1) menambahkan variabel prediktor lain seperti kelembapan relatif, tutupan awan, dan data satelit/radar cuaca untuk memperkaya representasi kondisi atmosfer; (2) melakukan optimasi *hyper parameter model* (misalnya jumlah *neuron*, jumlah lapisan tersembunyi, dan *learning rate*) melalui teknik seperti *grid search* atau *Bayesian optimization*; (3) membandingkan performa algoritma *Backpropagation* dengan metode pembelajaran mesin lain seperti *Random Forest, Support Vector Machine*, atau model berbasis time series seperti LSTM; serta (4) mengkaji lebih lanjut dampak SMOTE terhadap generalisasi model, misalnya dengan membandingkan performa model yang dilatih dengan dan tanpa teknik *oversampling* tersebut.

Pustaka

[1] Kurniasari, E., nurhayati, N., & Akbar, A. A. (2021). Intensitas curah hujan dan fluktuasi muka air tanah di kawasan lahan gambut di jalan reformasi kota Pontianak. *Jurnal teknik sipil*, 21(2), 254-258.

[2] Fitriana, Z. E., Putra, Y. S., & Zulfian, Z. (2021). Pengaruh Kerapatan Vegetasi terhadap Suhu Permukaan menggunakan Data Landsat 8 (Study Kasus: Kota Pontianak, Kalimantan Barat). *Prisma Fisika*, 9(2), 152-159.

[3] Nelvi, A., & Nata, R. A. (2024). Durasi penyinaran matahari dan diurnal temperature range serta kaitannya dengan perubahan iklim di pontianak, indonesia. *Jurnal Meteorologi dan Geofisika,* 24(2), 65 76.

[4] Rachmawati, A. (2015). Prediksi Curah Hujan Di Kota Pontianak Menggunakan Parameter Cuaca Sebagai Prediktor Pada Skala Bulanan, Dasarian dan Harian. *Positron*, 5(2).

[5] Manalu, M. T. (2016). Jaringan Syaraf Tiruan untuk Memprediksi Curah Hujan Sumatera Utara dengan Metode *Back Propagation* (Studi Kasus: BMKG Medan). *Jurikom* (Jurnal Ris. Komputer), 3(1), 35-40.

[6] Aprianto, Y., Nurhasanah, N., & Sanubary, I. (2018). Prediksi Kadar *Particulate Matter* (PM10) untuk Pemantauan Kualitas Udara Menggunakan Jaringan Syaraf Tiruan Studi Kasus Kota Pontianak. *Positron*, 8(1), 15-20.

[7] Tamaji, T., Utama, Y. A. K., & Sidharta, J. (2022). Jaringan Saraf Tiruan Menggunakan Metode Backpropagation untuk Prediksi Curah Hujan. Telekontran: Jurnal Ilmiah Telekomunikasi,Kendali dan Elektronika Terapan, 10(1), 30-37.

[8] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436–444.
[9] Kurniawan, K., Ceasaro, B., & Sucipto, S. (2023). Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai. *Jurnal Edukasi dan Penelitian Informatika* (JEPIN), 10(1), 134.
[10] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
[11] Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366.
[12] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
[13] Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37–46.
[14] Delgado, R., & Tibau, X.-A. (2019). Why Cohen's Kappa should be avoided as performance measure in classification. *PLOS ONE*, 14(9), e0222916.
[15] Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174.
[16] Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357.
[17] Elreedy, D., & Atiya, A. F. (2019). A comprehensive analysis of synthetic minority oversampling technique (SMOTE) for handling class imbalance. *Information Sciences*, 505, 32–64.
[18] Hall, T., Brooks, H. E., & Doswell, C. A. (1999). Precipitation forecasting using a neural network. *Weather and Forecasting*, 14(3), 338–345.
[19] Aldrian, E., & Dwi Susanto, R. (2003). Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature. *International Journal of Climatology*, 23(12), 1435–1452.