



PREDIKSI KASUS DEMAM BERDARAH DENGUE DI KABUPATEN BOGOR MENGGUNAKAN METODE ANN

Ilham Hafidz¹, Murniyati^{2*}

Program Studi Informatika^{1,2}
Fakultas Teknologi Industri^{1,2}
Universitas Gunadarma^{1,2}

*Correspondent Author: murnirk77@gmail.com

Author Email: ilhamhafidz666@gmail.com¹,
murni_rk77@gmail.com^{2*}

Received: November 15, 2025. **Revised:** December 23, 2025. **Accepted:** December 25, 2025. **Issue Period:** Vol.9 No.2 (2025), Pp. 460-467

Abstrak: Demam Berdarah Dengue (DBD) menjadi masalah kesehatan signifikan di Kabupaten Bogor dengan fluktuasi kasus yang sangat dipengaruhi oleh faktor iklim. Penelitian ini bertujuan merancang dan membangun model prediksi untuk memproyeksikan jumlah kasus DBD tahunan berdasarkan data iklim historis. Metode yang digunakan adalah Artificial Neural Network (ANN) dengan algoritma Backpropagation, dilatih menggunakan data deret waktu dari 2014-2023 yang mencakup variabel iklim (curah hujan, suhu, dan kelembapan) sebagai input. Melalui serangkaian eksperimen manual tuning untuk mengatasi underfitting dan overfitting, ditemukan konfigurasi model final terbaik dengan arsitektur [33 18] dan parameter regularisasi 0.4. Model menunjukkan kinerja kuat pada data latih (RMSE = 280.7; R^2 = 0.89). Validasi pada data uji 2024 menunjukkan kemampuan generalisasi yang tinggi, dengan RMSE 186.8 (error ~5.5%) dan R^2 0.99. Implementasi model menghasilkan prediksi 1484 kasus DBD untuk tahun 2025. Hasil ini menunjukkan bahwa model ANN yang dikembangkan dapat menjadi alat pendukung keputusan yang andal bagi pemangku kepentingan kesehatan.

Kata kunci: Prediksi, DBD, ANN, Bogor

Abstract: Dengue Hemorrhagic Fever (DHF) is a significant public health problem in Bogor Regency, with case fluctuations strongly influenced by climatic factors. This research aims to design and build a prediction model to project the annual number of DHF cases based on historical climate data. The method used is an Artificial Neural Network (ANN) with the Backpropagation algorithm, trained using time-series data from 2014-2023 which includes climate variables (rainfall, temperature, and humidity) as input. Through a series of manual tuning experiments to overcome underfitting and overfitting, the best final model configuration was found with a [33 18] architecture and a regularization parameter of 0.4. The model showed strong performance on the training data (RMSE = 280.7; R^2 = 0.89). Validation on the



DOI: 10.52362/jisicom.v9i2.2219

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).



2024 test data demonstrated high generalization capability, with an RMSE of 186.8 (error ~5.5%) and an R^2 of 0.99. The model implementation resulted in a prediction of 1484 DHF cases for 2025. These results indicate that the developed ANN model can serve as a reliable decision-support tool for public health stakeholders.

Keywords: Prediction, DBD, ANN, Bogor

I. PENDAHULUAN

Demam Berdarah Dengue (DBD) merupakan salah satu penyakit menular yang menjadi permasalahan kesehatan masyarakat di wilayah tropis seperti Indonesia, di mana Kabupaten Bogor secara konsisten mencatatkan jumlah kasus yang signifikan [1]. Berbagai penelitian menunjukkan adanya korelasi kuat antara faktor iklim—khususnya curah hujan, suhu, dan kelembapan—dengan siklus hidup dan penyebaran nyamuk *Aedes aegypti* sebagai vektor penyebar virus dengue [2], [3]. Suhu yang lebih tinggi terbukti berkorelasi dengan insiden DBD yang lebih tinggi, sementara fluktuasi curah hujan memengaruhi tempat perkembangbiakan nyamuk [4]. Oleh karena itu, kemampuan untuk memprediksi potensi kasus DBD berdasarkan dinamika iklim menjadi sangat krusial untuk mendukung langkah preventif dan kebijakan kesehatan masyarakat yang efektif.

Seiring perkembangan teknologi, metode kecerdasan buatan seperti Artificial Neural Network (ANN) telah banyak digunakan untuk memodelkan hubungan non-linear yang kompleks antara faktor lingkungan dengan kejadian penyakit [5]. Penelitian sebelumnya oleh Rahayu, dkk. (2019) berhasil memprediksi kasus DBD di Pontianak dengan akurasi tinggi ($R^2 = 0,85$) menggunakan ANN [6]. Studi lain juga menunjukkan bahwa penggunaan ANN dapat mengungguli metode statistik tradisional dalam memprediksi fenomena berbasis iklim [7]. Meskipun demikian, penerapan dan optimisasi model ANN pada dataset deret waktu yang terbatas untuk konteks wilayah Kabupaten Bogor masih menjadi area yang perlu dieksplorasi secara mendalam, terutama dalam mengatasi tantangan overfitting dan underfitting. Penelitian ini bertujuan untuk merancang, membangun, dan mengevaluasi model ANN Backpropagation yang optimal untuk memprediksi potensi kasus DBD tahunan di Kabupaten Bogor, dengan harapan dapat memberikan gambaran tren sebagai alat bantu pengambilan keputusan bagi dinas kesehatan terkait.

II. METODE DAN MATERI

Metode penelitian yang digunakan memiliki beberapa tahapan yang terstruktur untuk menghasilkan tujuan penelitian yang efektif.

2.1. Tahapan Penelitian

Penelitian ini dilaksanakan melalui enam tahapan utama yang sistematis, seperti yang digambarkan pada Gambar 1.





Gambar 1. Tahapan Penelitian

Alur penelitian pada Gambar 1 dimulai dengan tahap pengumpulan data, Data yang telah dikumpulkan kemudian melewati serangkaian pra-pemrosesan untuk memastikan kualitas data. Pembangunan model prediksi iklim secara terpisah untuk menghasilkan data input masa depan. Setelah itu dilanjutkan proses perancangan dan pelatihan model utama prediksi DBD. Model yang telah dibuat kemudian diuji kinerjanya pada tahap evaluasi dan validasi. Tahap terakhir adalah implementasi, di mana model yang telah diuji digunakan untuk menghasilkan prediksi final, yang kemudian dianalisis untuk penarikan kesimpulan.

2.2. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari Data iklim harian berupa data curah hujan, suhu rata-rata, dan kelembapan rata-rata yang diperoleh dari Stasiun Meteorologi Citeko dan BMKG dengan rentang waktu data dari tahun 2014 hingga tahun 2024. Serta data jumlah kasus DBD tahunan untuk wilayah Kabupaten Bogor diperoleh dari portal data.go.id. Total dataset yang digunakan mencakup 11 sampel data tahunan, dimana setiap sampel data terdiri dari 36 fitur input (3 variabel iklim \times 12 bulan) dan 1 nilai target (total kasus DBD pada tahun terkait).

2.3. Pra-Pemrosesan Data

Tahap pra-pemrosesan data bertujuan untuk memastikan data bersih, konsisten, dan siap untuk diproses oleh model ANN. Langkah-langkah yang dilakukan meliputi:

- **Pembersihan Data (*Data Cleaning*):** Menangani nilai yang hilang (*missing values*) atau tidak valid (misalnya, nilai 8888) pada data iklim harian menggunakan estimasi berbasis data historis.
- **Agregasi Data:** Mengubah data iklim harian menjadi data bulanan. Curah hujan dihitung sebagai total penjumlahan per bulan, sedangkan suhu dan kelembapan dihitung sebagai nilai rata-rata bulanan.
- **Normalisasi Data:** Menskalakan seluruh nilai fitur dan target menggunakan metode *Min-Max Normalization* ke dalam rentang $[-1, 1]$ agar sesuai dengan fungsi aktivasi yang digunakan dan untuk meningkatkan stabilitas pelatihan.
- **Pembagian Data (*Splitting Data*):** Dataset dibagi secara kronologis menjadi 10 sampel untuk data latih (periode 2014–2023) dan 1 sampel untuk data uji (periode 2024).

2.4. Perancangan Arsitektur Model

Metode yang digunakan adalah Artificial Neural Network (ANN) dengan algoritma Backpropagation, yang diimplementasikan sebagai Feedforward Neural Network. Arsitektur model final ditentukan berdasarkan



serangkaian eksperimen manual tuning untuk mendapatkan keseimbangan terbaik antara underfitting dan overfitting. Arsitektur yang terpilih terdiri dari:

- Satu lapisan input dengan 36 neuron, sesuai dengan jumlah fitur iklim.
- Dua lapisan tersembunyi (hidden layers) dengan 33 dan 18 neuron. Fungsi aktivasi yang digunakan adalah *Tangent Sigmoid* (tansig).
- Satu lapisan output dengan 1 neuron tunggal. Fungsi aktivasi yang digunakan adalah Linear (purelin), yang cocok untuk tugas regresi.

2.5. Pelatihan dan Evaluasi Model

Proses pelatihan model diimplementasikan menggunakan toolbox pada aplikasi MATLAB. Konfigurasi pelatihan diatur dengan algoritma optimisasi *Levenberg-Marquardt* (trainlm) yang dikenal efisien untuk dataset berukuran kecil. Untuk mencegah *overfitting*, digunakan fungsi performa *Mean Squared Error with Regularization* (msereg) dengan parameter regularisasi yang ditetapkan pada nilai 0.4.

Kinerja dan akurasi model dievaluasi menggunakan dua metrik utama yang umum digunakan dalam masalah regresi:

- *Root Mean Squared Error* (RMSE): Mengukur rata-rata simpangan kesalahan prediksi dalam satuan yang sama dengan data target (jumlah kasus).
- Koefisien Determinasi (R^2): Mengukur seberapa baik model mampu menjelaskan variasi yang ada pada data target.

III. PEMBAHASAN DAN HASIL

Bagian ini menyajikan hasil dari proses eksperimental sistematis yang dilakukan untuk menentukan konfigurasi model ANN terbaik, menganalisis kinerjanya secara mendalam, serta memaparkan hasil prediksi akhir.

3.1. Analisis Skenario Eksperimen dan Penentuan Model Final

Penentuan model final dilakukan melalui proses manual *tuning* untuk menemukan keseimbangan optimal antara *underfitting* dan *overfitting*. Beberapa skenario dengan kombinasi arsitektur dan parameter yang berbeda diuji, di mana hasilnya dirangkum pada Tabel 1. Skenario A, yang menggunakan fungsi latihan *trainbr*, menunjukkan *underfitting* yang parah (R^2 Latih = -1.72), yang mengindikasikan model terlalu sederhana untuk menangkap pola data. Sebaliknya, Skenario B dengan nilai regularisasi yang lemah menunjukkan *overfitting* signifikan (RMSE Uji = 2800), di mana model memiliki performa sangat baik pada data latihan namun gagal total pada data uji. Berdasarkan analisis komparatif, konfigurasi dari Skenario C terpilih sebagai model final karena berhasil mencapai kemampuan generalisasi terbaik, yang ditandai dengan nilai RMSE terendah pada data uji (RMSE Uji = 186) tanpa mengorbankan kinerja pada data latihan secara signifikan.

Tabel 1. Perbandingan Skenario Eksperimen

Skenario	Arsitektur	Fungsi Latih	Fungsi Aktivasi	Regularisasi	RMSE (Latih)	RMSE (Uji)	R^2 (Latih)	R^2 (Uji)	Diagnosis
A	[33, 18]	trainbr	tansig	0,2	833	1.809	-1,723	0,5232	Underfitting
B	[25, 15]	trainlm	tansig	0,95	193	2800	0,9461	-0,129	Overfitting
C	[33, 18]	trainlm	tansig	0,4	280	186	0,8886	0,9943	Model Final Terpilih
D	[25, 15]	trainlm	logsig	0,4	2753	1257	-9,914	0,7724	Kurang Optimal




DOI: 10.52362/jisicom.v9i2.2219

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

3.2. Kinerja Model Final pada Data Latih

Kinerja model final pada data latih periode 2014-2023 menunjukkan kemampuan yang sangat baik dalam mempelajari pola historis. Seperti terlihat pada Gambar 2, garis prediksi model (biru) mampu mengikuti tren umum dari data aktual (merah), termasuk menangkap pola penurunan dan kenaikan kasus pada periode-periode tertentu. Secara kuantitatif, model mencapai nilai RMSE sebesar 280.7 dan R^2 sebesar 0.89. Nilai R^2 yang tinggi ini mengindikasikan bahwa model berhasil menjelaskan 89% dari total variasi pada data historis kasus DBD, yang membuktikan bahwa model telah berhasil dilatih dengan baik dan mampu menangkap hubungan non-linear yang signifikan.

secara keseluruhan, kombinasi dari nilai R-squared yang tinggi dengan tingkat error (RMSE/MAE) yang terkontrol membuktikan bahwa model final telah berhasil mempelajari pola hubungan yang signifikan antara data iklim dan kasus DBD dari data latih yang diberikan. Untuk analisis kualitatif, Gambar 2 menyajikan perbandingan visual antara data aktual dengan hasil prediksi model pada periode 2014-2023.

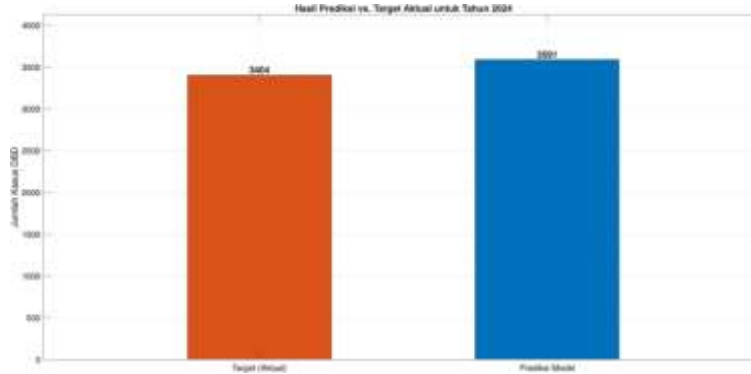


Gambar 2. Perbandingan Prediksi vs Aktual pada Data Latih

Seperti yang terlihat pada gambar 2, dimana model pelatihan mampu menangkap pola penurunan kasus pada periode 2016-2017 serta tren kenaikan pada periode 2018-2021. Meskipun model tidak mereplikasi puncak-puncak ekstrem secara sempurna, justru menandakan bahwa model pelatihan tidak overfitting kemampuannya dalam mengikuti arah pergerakan data menunjukkan bahwa model telah berhasil mempelajari pola hubungan yang signifikan. Kombinasi dari metrik kuantitatif yang kuat dan kecocokan visual pada grafik ini membuktikan bahwa model telah berhasil dilatih dengan baik.

3.3. Kinerja Generalisasi Model pada Data Uji

Tahap evaluasi paling krusial adalah pengujian pada data uji tahun 2024, yang merupakan data baru yang tidak pernah dilihat oleh model. Pada tahap ini, model menunjukkan kemampuan generalisasi yang sangat tinggi. Seperti yang divisualisasikan pada Gambar 3, model berhasil memprediksi 3591 kasus, sangat mendekati nilai aktual sebesar 3404 kasus. Kinerja ini divalidasi secara kuantitatif dengan nilai RMSE yang sangat rendah, yaitu 186.8, yang merepresentasikan error prediksi hanya sekitar 5.5% dari nilai aktual. Lebih lanjut, nilai R^2 pada data uji mencapai 0.99, yang merupakan bukti kuantitatif terkuat dari kemampuan generalisasi model dan menunjukkan bahwa model berhasil menghindari *overfitting*.



Gambar 3. Perbandingan Prediksi vs Aktual pada Data Uji (2024)

Visualisasi pada gambar 3 ini secara jelas mengkonfirmasi hasil metrik kuantitatif pada Tabel 4.4, yang menunjukkan *error* prediksi yang rendah. Kedekatan antara nilai prediksi dan nilai aktual ini merupakan bukti kuat dari kemampuan generalisasi model yang andal pada data baru.

Lalu untuk mengukur kemampuan generalisasinya. Hasil kinerja model pada data uji secara kuantitatif dirangkum pada tabel 2.

Tabel 2. Metrik Kinerja Model Final pada Data Uji (2024)

Metrik	Nilai
R^2	0,994
RMSE	186,7
MAE	186,8
MSE	34881

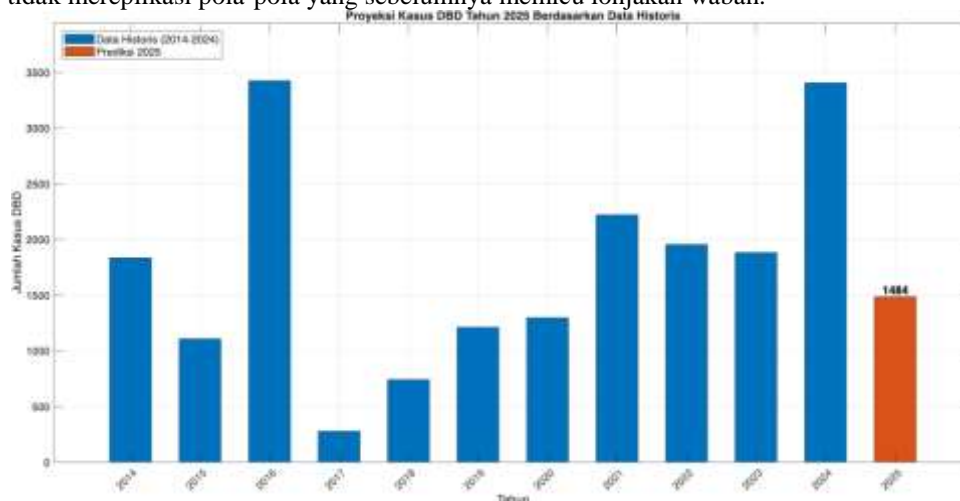
Berdasarkan Tabel 2, model final menunjukkan kinerja yang sangat baik dan akurat saat diuji pada data tahun 2024. Analisis mendalam terhadap setiap metrik pada data uji adalah sebagai berikut:

- Koefisien Determinasi (R^2). Pada uji luar-sampel 2024, $R^2 = 0,994$, menunjukkan model menjelaskan hampir seluruh variasi data uji dan melampaui baseline rata-rata. Nilai tinggi ini mengindikasikan generalisasi kuat dan keberhasilan regularisasi dalam mencegah overfitting.
- Root Mean Squared Error (RMSE). RMSE = 186,8 kasus pada 2024, setara $\approx 5,5\%$ dari nilai aktual (3.404). Deviasi yang rendah ini menegaskan akurasi prediksi yang tinggi pada data baru.
- Mean Absolute Error (MAE). MAE = 186,8 kasus, merefleksikan selisih mutlak rata-rata antara prediksi (3.591) dan aktual (3.404). Sebagai metrik linear, MAE menguatkan konsistensi temuan akurasi tanpa memberi bobot berlebih pada galat besar.

- Mean Squared Error (MSE). $MSE = 34.881,69$ (satuan “kasus²”), menandakan galat rata-rata terkuadrat yang rendah dan tidak adanya outlier prediksi yang ekstrem. MSE ini menjadi dasar matematis RMSE dan memvalidasi rendahnya galat generalisasi model.

3.4. Implementasi Prediksi dan Validasi Hasil

Implementasi model final dengan input data iklim tahun 2025 yang telah diestimasi sebelumnya menghasilkan prediksi utama penelitian, yaitu bahwa potensi jumlah kasus DBD di Kabupaten Bogor untuk tahun 2025 adalah 1484 kasus. Angka ini, jika diposisikan dalam konteks data historis seperti pada Gambar 4, mengindikasikan adanya potensi tren penurunan yang signifikan dibandingkan dengan tahun-tahun terkini (2021-2024) dan lebih sebanding dengan level kasus pada periode 2019-2020. Penurunan ini dapat diinterpretasikan bahwa kombinasi fitur iklim yang diprediksi untuk tahun 2025, saat diproses oleh model, cenderung tidak mereplikasi pola-pola yang sebelumnya memicu lonjakan wabah.



Gambar 4. Proyeksi Kasus DBD Tahun 2025

Untuk melakukan validasi awal terhadap hasil prediksi ini, dilakukan perbandingan dengan data riil parsial yang tersedia. Berdasarkan laporan media Radar Bogor (19 Agustus 2025), jumlah kasus DBD dari Januari hingga pertengahan Agustus 2025 telah mencapai 1.372 kasus. Angka riil parsial ini menunjukkan bahwa prediksi model berada dalam rentang yang realistis. Meskipun total kasus riil di akhir tahun diproyeksikan akan melampaui angka yang diprediksi model, temuan ini tetap memberikan validasi penting: model berhasil mengidentifikasi bahwa tahun 2025 akan menjadi tahun dengan kasus yang signifikan menurun, sejalan dengan tujuannya sebagai alat peringatan dini. Perbedaan antara nilai prediksi dan tren data riil ini juga secara nyata menggarisbawahi keterbatasan penelitian yang telah diuraikan, yaitu cakupan variabel yang hanya terbatas pada faktor iklim, dan memperkuat urgensi untuk penelitian selanjutnya agar mengintegrasikan faktor non-iklim.

IV. KESIMPULAN

Penelitian ini berhasil merancang, membangun, dan mengevaluasi model Artificial Neural Network (ANN) yang andal untuk memprediksi potensi kasus DBD tahunan di Kabupaten Bogor berdasarkan faktor iklim. Melalui proses tuning sistematis, ditemukan bahwa konfigurasi model dengan arsitektur [33 18] dan parameter regularisasi 0.4 mampu mengatasi tantangan overfitting pada dataset terbatas, serta menunjukkan kemampuan generalisasi yang tinggi dengan error prediksi hanya sekitar 5.5% pada data uji. Implementasi model menghasilkan proyeksi 1484 kasus untuk tahun 2025, yang divalidasi secara parsial dengan data riil dan terbukti relevan. Hasil penelitian ini memberikan kontribusi berupa model prediktif yang dapat diadopsi oleh Dinas Kesehatan Kabupaten Bogor sebagai alat bantu dalam sistem peringatan dini. Meskipun memiliki keterbatasan





e-ISSN : 2597-3673 (Online) , p-ISSN : 2579-5201 (Printed)

Vol.9 No.2 (December 2025)

Journal of Information System, Informatics and Computing

Website/URL: <http://journal.stmikjayakarta.ac.id/index.php/jisicom>

Email: jisicom@stmikjayakarta.ac.id , jisicom2017@gmail.com

terkait jumlah data dan cakupan variabel, model ini dapat menjadi dasar untuk perencanaan program pencegahan yang lebih strategis dan proaktif. Penelitian selanjutnya disarankan untuk mengembangkan dataset dengan rentang waktu yang lebih panjang dan mengintegrasikan faktor non-iklim untuk meningkatkan akurasi model.

REFERENASI

- [1] Rakhmatsani, L. and Susanna, D. (2024) “Studi Ekologi Hubungan Iklim Terhadap Kejadian Demam Berdarah Dengue (DBD) di Kabupaten Bogor Tahun 2013-2022,” *Jurnal Kesehatan Lingkungan Indonesia*, 23(2), pp. 207–214.
- [2] SUMI, A. et al. (2017) “Effect of temperature, relative humidity and rainfall on dengue fever and leptospirosis infections in Manila, the Philippines,” *Epidemiology and Infection*, 145(1), pp. 78–86.
- [3] Li, Y. et al. (2020) “Effects of ambient temperature and precipitation on the risk of dengue fever: A systematic review and updated meta-analysis,” *Environmental Research*, 191, p. 110043.
- [4] Rahmawati, Y., Jamil, I.R. and Hidayah, I. (2025) “A Spatial Analysis on Heterogenous Determinant of Dengue Fever Cases in Indonesia,” *Journal of Geovisualization and Spatial Analysis*, 9(1), p. 10.
- [5] Wong, Z.S.Y., Zhou, J. and Zhang, Q. (2019) “Artificial Intelligence for infectious disease Big Data Analytics,” *Infection, Disease & Health*, 24(1), pp. 44–48.
- [6] Rahayu, D. et al. (2019) “Prediksi Jumlah Kasus Demam Berdarah Dengue (DBD) Berdasarkan Faktor Iklim Menggunakan Jaringan Saraf Tiruan Backpropagation,” *Jurnal Sistem dan Teknologi Informasi (JUSTIN)*, 7(4), p. 235.
- [7] Gunawan, I. et al. (2024) “Hybrid Model of Artificial Neural Network and Genetic Algorithm for Weather Prediction,” *Journal of Information Systems Engineering and Business Intelligence*, 10(1),



DOI: 10.52362/jisicom.v9i2.2219

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).