

Integrasi Artificial Neural Network dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal

Muhammad Miftakhudin¹, Aang Alim Murtopo², Zaenul Arif³

¹²³Teknik Informatika, STMIK YMI Tegal

¹muhammadmiftakhudin588@gmail.com^{*}, ²aang.murtopo@gmail.com^{*}, ³zendhunter@gmail.com

Abstrak

Banjir merupakan ancaman rutin di Kota Tegal yang disebabkan oleh curah hujan tinggi, buruknya drainase, dan kenaikan muka air laut. Penelitian ini bertujuan mengembangkan model prediksi banjir berbasis kecerdasan buatan menggunakan Artificial Neural Network (ANN) yang dioptimasi dengan Algoritma Genetika (AG). Data cuaca harian tahun 2024–2025 dari BMKG digunakan sebagai basis pelatihan, mencakup variabel seperti temperatur, curah hujan, kelembapan, dan kecepatan angin. Model ANN bertipe Multilayer Perceptron (MLP) digunakan untuk mengenali pola non-linier, sementara AG mengoptimasi hyperparameter penting guna meningkatkan akurasi. Evaluasi kinerja model dilakukan menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Hasil menunjukkan bahwa model ANN yang telah dioptimasi dengan AG mengalami peningkatan akurasi signifikan dibandingkan model baseline tanpa optimasi, dengan penurunan MAE sebesar 19,63% dan RMSE sebesar 26,31%. Temuan ini menunjukkan bahwa pendekatan hibrida ANN-AG efektif digunakan dalam prediksi bencana banjir berbasis data cuaca. Model ini berpotensi diimplementasikan dalam sistem peringatan dini banjir yang adaptif dan akurat di wilayah pesisir.

Kata kunci: Prediksi Banjir, Artificial Neural Network, Algoritma Genetika, Optimasi Model, Data Cuaca.

1. Latar Belakang

Banjir merupakan salah satu bencana alam yang paling sering melanda wilayah Indonesia, terutama selama musim hujan, dan telah menjadi permasalahan tahunan yang sulit dihindari di berbagai daerah [1]. Kota Tegal, sebagai salah satu kota pesisir di Pulau Jawa, tidak terkecuali dari ancaman bencana ini. Letaknya yang berbatasan langsung dengan Laut Jawa serta topografi yang relatif datar menjadikan wilayah ini sangat rentan terhadap limpasan air hujan yang berlebihan [2]. Ancaman banjir di Kota Tegal diperparah oleh beberapa faktor utama, seperti tingginya intensitas curah hujan musiman, buruknya sistem drainase dan saluran air, serta fenomena kenaikan muka air laut (rob) yang terjadi secara berkala. Dampak dari kejadian banjir tidak hanya bersifat fisik, berupa kerusakan infrastruktur dan kerugian material, tetapi juga mempengaruhi kelangsungan aktivitas sosial, ekonomi, pendidikan, bahkan kesehatan masyarakat secara keseluruhan. Oleh karena itu, dibutuhkan suatu sistem prediksi banjir yang bersifat cepat, akurat, dan adaptif untuk mendukung proses mitigasi risiko bencana serta pengambilan keputusan yang responsif oleh instansi terkait [3].

Selama ini, berbagai metode konvensional telah digunakan untuk memodelkan dan memprediksi kejadian banjir, seperti *regresi linier*, *analisis statistik* sederhana, dan pendekatan berbasis *threshold*. Namun demikian, metode-metode tersebut memiliki keterbatasan dalam menangkap dinamika dan ketidaklinieran dari data hidrometeorologi yang sangat kompleks [4]. Hubungan antara parameter cuaca seperti curah hujan, suhu, kelembapan udara, kecepatan angin, dan tekanan atmosfer tidak bersifat linier dan sering kali berubah secara dinamis. Untuk menjawab tantangan tersebut, pendekatan berbasis kecerdasan buatan (*Artificial Intelligence/AI*), khususnya *Artificial Neural Network* (ANN), mulai banyak digunakan dalam sistem prediksi bencana [5].

ANN merupakan salah satu model pembelajaran machine learning yang terinspirasi dari struktur dan cara kerja jaringan saraf biologis pada otak manusia [6]. Model ini memiliki keunggulan dalam mengenali pola dan hubungan non-linier pada data berukuran besar dan tidak terstruktur. ANN mampu menyesuaikan bobot antar node dalam jaringannya selama proses pelatihan untuk memetakan input terhadap output secara akurat [7]. Namun, performa ANN sangat bergantung pada struktur arsitekturnya dan parameter pelatihan seperti jumlah *neuron*, jumlah *layer*

tersembunyi, *learning rate*, dan *batch size*. Pemilihan konfigurasi yang tidak tepat dapat menyebabkan *overfitting*, *underfitting*, atau hasil prediksi yang tidak stabil dan sulit direproduksi [8].

Salah satu cara mengatasi keterbatasan tersebut, Algoritma Genetika (AG) diperkenalkan sebagai metode optimasi yang mampu meningkatkan efisiensi dan akurasi model ANN. AG merupakan salah satu metode pencarian global berbasis mekanisme seleksi alam dan evolusi biologis, yang bekerja melalui proses seleksi, *crossover* (rekombinasi), dan mutasi terhadap populasi solusi [9]. Dengan menggunakan AG, proses pencarian kombinasi *hyperparameter* terbaik dalam ruang solusi ANN dapat dilakukan secara iteratif dan otomatis, tanpa harus melalui proses pencobaan manual yang memakan waktu. Integrasi antara ANN dan AG membentuk pendekatan hibrida yang menggabungkan kekuatan representasi ANN dengan kapabilitas eksploratif AG dalam menemukan konfigurasi parameter optimal [10].

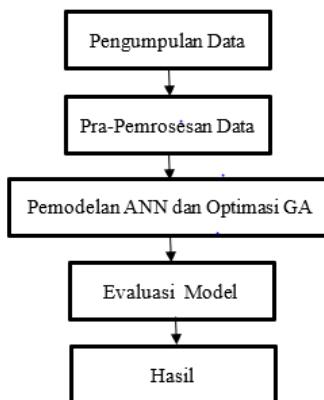
Berbagai studi sebelumnya telah menunjukkan potensi besar dari kombinasi ANN dan AG dalam berbagai bidang prediktif. Misalnya, Alfajri menerapkan ANN untuk memprediksi banjir berdasarkan data curah hujan dan kelembapan, dan mendapatkan tingkat akurasi yang cukup tinggi [11]. Sementara itu, penelitian oleh Zhu et al berhasil mengoptimasi struktur ANN menggunakan berbagai fungsi pelatihan dan dataset hybrid, yang secara signifikan meningkatkan performa prediksi terhadap genangan banjir di daerah perkotaan [12]. Dengan demikian, penguatan model ANN melalui optimasi menggunakan AG dapat menjadi strategi efektif dalam mengembangkan sistem prediksi banjir yang lebih presisi dan adaptif.

Penelitian ini bertujuan untuk mengembangkan model prediksi banjir harian di Kota Tegal dengan memanfaatkan data cuaca dan hidrologi tahun 2024–2025 yang diperoleh dari BMKG dan instansi terkait lainnya. Model dibangun menggunakan arsitektur *Artificial Neural Network* bertipe *Multilayer Perceptron* (MLP), yang kemudian dioptimasi menggunakan Algoritma Genetika untuk memperoleh konfigurasi *hyperparameter* terbaik secara otomatis [13]. Hasil model dievaluasi berdasarkan akurasi prediksi, yang diukur menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem prediksi banjir berbasis data yang lebih akurat dan dapat digunakan sebagai komponen penting dalam sistem peringatan dini bencana di daerah rawan banjir seperti Kota Tegal [14].

2. Metode Penelitian

2.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan menerapkan algoritma *Artificial Neural Network* (ANN) yang kemudian dioptimalkan menggunakan Algoritma Genetika (AG) guna membangun sistem prediksi bencana banjir yang akurat. Metode ini dipilih karena ANN terbukti mampu menangani kompleksitas hubungan non-linier dalam data cuaca dan hidrologi, sementara AG berfungsi sebagai algoritma optimasi global untuk mencari konfigurasi parameter ANN yang optimal.



Gambar 1. Proses Analisis Data

2.2. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Tegal. Dataset mencakup data cuaca harian selama periode 1 Januari 2024 hingga 13 April 2025, dengan total sebanyak 470 baris data yang mewakili kondisi atmosfer dan hidrologi di wilayah pengamatan. Setiap entri data terdiri dari sejumlah atribut yang memiliki keterkaitan langsung dengan potensi terjadinya banjir.

Tabel 1. Dataset cuaca periode 1 Januari 2024 hingga 13 April 2025

Tanggal	Temperatur minimum (°C)	Temperatur maksimum(°C)	Temperatur rata-rata(°C)	Arah angin terbanyak(°)	Ketinggian Permukaan Tanah (mdpl)	Banjir (1=banjir 0=tidak)
01/01/2024	9999	33,8	29,5			225	7	0
02/01/2024	26,2	34,2	29,6			180	7	0
03/01/2024	25	32,7	28,8			180	7	0
⋮								⋮
⋮								⋮
⋮								⋮
12/04/2025	25,2	0	27,5			90	7	0
13/04/2025	24,2	32,2	28,1	90	7	0

Tabel 1. menampilkan data cuaca harian selama periode 1 Januari 2024 hingga 13 April 2025. Atribut-atribut tersebut meliputi tanggal, temperatur minimum, maksimum, dan rata-rata (dalam derajat Celcius), kelembapan udara rata-rata (dalam persen), curah hujan harian (dalam milimeter), serta lama penyinaran matahari (dalam jam). Selain itu, terdapat pula data kecepatan angin maksimum dan rata-rata (dalam meter per detik), arah angin saat kecepatan maksimum dan arah angin terbanyak (dalam derajat), ketinggian permukaan tanah (dalam meter di atas permukaan laut), dan debit sungai (dalam meter kubik per detik). Atribut terakhir adalah label banjir, yang berisi nilai biner (1 untuk "terjadi banjir", dan 0 untuk "tidak terjadi banjir"), dan digunakan sebagai variabel target dalam pelatihan model.

2.3. Pra-pemrosesan Data

Sebelum digunakan dalam proses pelatihan model, data yang dikumpulkan terlebih dahulu melalui tahap pra-pemrosesan guna memastikan kualitas, konsistensi, dan kesiapan data untuk dimasukkan ke dalam algoritma kecerdasan buatan. Proses pra-pemrosesan ini menjadi langkah penting dalam pipeline machine learning karena kualitas data yang buruk dapat berdampak langsung terhadap kinerja prediktif model.

Langkah pertama yang dilakukan adalah pembersihan data, yaitu menghapus baris-baris data yang duplikat serta mengatasi nilai-nilai kosong (*missing values*). Untuk nilai yang hilang, dilakukan pendekatan imputasi menggunakan nilai rata-rata atau interpolasi berdasarkan waktu, agar tidak mengganggu struktur distribusi data. Setelah pembersihan, data numerik seperti temperatur, curah hujan, kelembapan, kecepatan angin, dan debit sungai dinormalisasi ke dalam rentang [0, 1] menggunakan teknik *Min-Max Normalization*. Normalisasi ini bertujuan untuk menyetarakan skala antar-fitur agar tidak ada variabel yang mendominasi proses pembelajaran hanya karena memiliki nilai numerik lebih besar.

Selain itu, atribut arah angin yang bersifat siklikal (0–360 derajat) diubah menjadi representasi *sinus* dan *cosinus* agar dapat ditangani lebih efektif oleh model ANN. Transformasi ini dilakukan karena model prediktif berbasis jaringan saraf tidak secara alami memahami bahwa arah 0° dan 360° secara semantik saling berdekatan. Seluruh hasil pra-pemrosesan disimpan dalam format yang telah disesuaikan dan siap digunakan untuk tahap selanjutnya, yaitu proses pelatihan dan optimasi model prediksi banjir berbasis ANN dan Algoritma Genetika. Dengan demikian, tahapan ini memastikan bahwa data yang digunakan bersih, seragam, dan representatif terhadap pola-pola kompleks yang ingin dipelajari oleh model.

2.4. Implementasi Artificial Neural Network

Model prediksi dalam penelitian ini dibangun menggunakan pendekatan *Artificial Neural Network* (ANN) dengan tipe arsitektur *Multilayer Perceptron* (MLP). ANN dipilih karena kemampuannya dalam mempelajari pola-pola kompleks dan non-linier yang sulit ditangkap oleh metode statistik konvensional. Struktur jaringan ANN yang digunakan terdiri dari satu input *layer*, beberapa *hidden layer*, dan satu output *layer*. Layer input menerima 14 fitur masukan yang telah melalui proses *normalisasi*, seperti temperatur, kelembapan, curah hujan, kecepatan angin, debit sungai, dan parameter hidrometeorologi lainnya. Fitur-fitur ini diasumsikan berkontribusi terhadap

kemungkinan terjadinya banjir. Jumlah neuron pada layer input disesuaikan dengan banyaknya atribut input yang relevan [15].

Hidden layer berfungsi untuk mengekstraksi pola *non-linier* antar fitur, dengan masing-masing neuron menggunakan fungsi aktivasi *ReLU* (*Rectified Linear Unit*). Fungsi ini dipilih karena efektif dalam mengatasi masalah vanishing gradient dan mempercepat proses konvergensi selama pelatihan. Pada lapisan output, digunakan fungsi aktivasi sigmoid untuk menghasilkan nilai prediksi dalam bentuk probabilitas antara 0 dan 1. Nilai ini merepresentasikan kemungkinan terjadinya banjir pada hari tertentu. Jika nilai prediksi mendekati 1, maka risiko banjir tinggi, sebaliknya, jika mendekati 0, maka risiko rendah.

Model ANN ini dilatih menggunakan algoritma optimasi Adam, dengan fungsi *loss Mean Squared Error* (MSE) dan metrik evaluasi *Mean Absolute Error* (MAE). Proses pelatihan dilakukan secara *iteratif* (*epoch*), dengan teknik validasi silang untuk memastikan bahwa model tidak hanya menghafal data latih tetapi juga mampu melakukan generalisasi terhadap data baru. Sebagai baseline, model ANN terlebih dahulu diimplementasikan dengan arsitektur tetap (tanpa optimasi) untuk mengetahui kinerjanya secara standar. Tahap ini menjadi acuan untuk kemudian dibandingkan dengan model ANN yang telah dioptimalkan menggunakan Algoritma Genetika (AG) pada tahap selanjutnya.

2.5. Optimasi dengan Algoritma Genetika

Setelah model *Artificial Neural Network* (ANN) dasar dibangun, tahap selanjutnya adalah proses optimasi *hyperparameter* menggunakan pendekatan Algoritma Genetika (AG). Tujuan utama dari tahap ini adalah untuk meningkatkan performa model ANN dengan menemukan konfigurasi parameter terbaik secara otomatis melalui simulasi proses evolusi biologis [16].

Algoritma Genetika bekerja dengan merepresentasikan setiap konfigurasi ANN sebagai individu dalam suatu populasi. Setiap individu membawa gen-gen yang mewakili *hyperparameter* ANN, seperti jumlah *hidden layer*, jumlah neuron per layer, nilai *dropout rate*, *learning rate*, dan ukuran *batch*. Proses optimasi dimulai dengan populasi awal yang dibentuk secara acak, yang kemudian dievolusikan melalui beberapa generasi.

Dalam setiap generasi, dilakukan proses seleksi individu-individu terbaik berdasarkan nilai *fitness* yang dalam konteks ini dihitung menggunakan gabungan dari nilai *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Semakin rendah kesalahan prediksi, semakin tinggi nilai *fitness*-nya. Selanjutnya, dilakukan proses *crossover* dua titik untuk menggabungkan gen dari dua individu yang dipilih, serta mutasi *Gaussian* untuk menjaga keberagaman populasi dan mencegah konvergensi prematur terhadap solusi lokal.

Proses evolusi ini terus berlangsung selama sejumlah generasi (misalnya 20 generasi), dengan evaluasi performa dilakukan terhadap setiap individu di setiap generasi menggunakan data pelatihan yang sama. Hasil dari setiap proses training digunakan untuk memperbarui nilai *fitness*, dan hanya individu dengan performa terbaik yang dipertahankan untuk membentuk populasi generasi berikutnya.

2.6. Metrik Evaluasi

Untuk menilai kualitas dan keakuratan dari model prediksi yang dibangun, dilakukan proses evaluasi model menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Kedua metrik ini dipilih karena mampu memberikan gambaran yang kuantitatif dan representatif terhadap tingkat kesalahan prediksi antara output model dengan nilai aktual [17].

Mean Absolute Error (MAE) mengukur rata-rata dari nilai absolut selisih antara prediksi dan data aktual. MAE bersifat intuitif dan mudah diinterpretasikan karena mempertimbangkan seluruh kesalahan secara merata tanpa memperbesar dampak kesalahan ekstrem. Nilai MAE yang rendah menunjukkan bahwa model memiliki tingkat kesalahan rata-rata yang kecil dalam melakukan prediksi. Rumus *Mean Absolute Error* (MAE) dapat dituliskan pada persamaan (1)

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (1)$$

n adalah jumlah sampel dalam data, y^i adalah aktual dan \hat{y}^i adalah nilai prediksi.

Sementara itu, *Root Mean Squared Error* (RMSE) memberikan bobot lebih besar terhadap kesalahan yang signifikan karena menggunakan kuadrat dari selisih prediksi dan nilai aktual sebelum diakarkan. Dengan demikian, RMSE sensitif terhadap prediksi yang meleset jauh, dan cocok digunakan untuk mengetahui apakah model menghasilkan outlier dalam prediksinya. Rumus *Root Mean Squared Error* (RMSE) dapat dituliskan pada persamaan (2)

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (2)$$

n adalah jumlah data, i adalah urutan data pada database, y_i adalah aktual dan \hat{y}_i adalah nilai prediksi.

3. Hasil dan Diskusi

Sebelum dilakukan proses pemodelan, data melalui tahap pra-pemrosesan guna memastikan kualitas dan konsistensi data yang digunakan. Tahapan ini meliputi pemeriksaan data duplikat, penanganan nilai kosong, serta normalisasi nilai numerik pada seluruh variabel. Proses ini penting untuk menghindari bias dalam pelatihan dan memastikan bahwa setiap fitur memiliki skala yang seimbang. Hasil dari pra-pemrosesan ini menjadi dasar dalam membangun model *Artificial Neural Network* (ANN) untuk prediksi kejadian banjir di Kota Tegal.

Tabel 2. Dataset yang sudah di Normalisasi

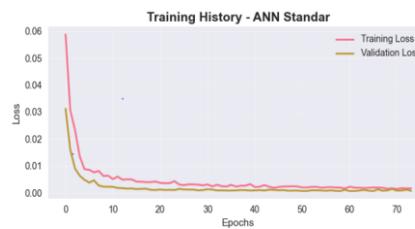
Tanggal	Temperatur minimum (°C)	Temperatur maksimum(°C)	Temperatur rata-rata(°C)	Arah angin terbanyak(°)	Ketinggian Permukaan Tanah (mdpl)	Banjir (1=banjir 0=tidak)
01/01/2024	26	33,8	29,5			225	7	0
02/01/2024	26,2	34,2	29,6			180	7	0
03/01/2024	25	32,7	28,8			180	7	0
:								:
:								:
:								:
12/04/2025	25,2	30,2	27,5			90	7	0
13/04/2025	24,2	32,2	28,1	90	7	0

Tabel 2. menampilkan hasil pra-pemrosesan data cuaca harian di Kota Tegal selama tahun 2024 hingga April 2025, yang mencakup atribut seperti tanggal, temperatur minimum, maksimum, dan rata-rata (°C), arah angin terbanyak (°), ketinggian permukaan tanah (mdpl), serta status banjir (1 = banjir, 0 = tidak banjir). Pada tahap ini telah dilakukan proses penghapusan data duplikat, serta penanganan *missing values* menggunakan pendekatan nilai rata-rata untuk memastikan kelengkapan dan konsistensi data.

Data yang telah melalui tahapan pra-pemrosesan ini kemudian digunakan dalam proses pemodelan prediksi banjir menggunakan metode *Artificial Neural Network* (ANN). Proses pelatihan model dilakukan menggunakan dua pendekatan, yaitu secara otomatis menggunakan bahasa pemrograman *Python* dan secara terkontrol melalui pemilihan parameter arsitektur jaringan dan skema evaluasi, guna memperoleh hasil prediksi yang akurat dan dapat diandalkan.

3.1. Hasil Pemodelan ANN Tanpa Optimasi

Model *Artificial Neural Network* (ANN) pertama dibangun menggunakan konfigurasi standar sebagai *baseline*, tanpa proses optimasi *hyperparameter*. Arsitektur yang digunakan terdiri dari tiga *hidden layer* dengan jumlah neuron tetap, menggunakan fungsi aktivasi *ReLU* di *hidden layer* dan *sigmoid* pada output layer. Model ini dilatih selama 75 epoch dengan algoritma optimasi *Adam* dan fungsi *loss* *Mean Squared Error* (MSE). Proses pelatihan menghasilkan kurva konvergensi yang stabil, sebagaimana ditampilkan pada Gambar 1.



Gambar 1. Proses pelatihan Epoch

Pada Gambar 1. yang menunjukkan penurunan nilai loss baik pada data pelatihan (*training loss*) maupun data validasi (*validation loss*). Kurva menunjukkan bahwa model mengalami penurunan loss yang tajam pada 10 *epoch* pertama, lalu melandai dan mencapai kondisi stabil setelah sekitar *epoch* ke-30. Hal ini mengindikasikan bahwa model berhasil belajar dari pola data dan tidak mengalami overfitting.

Setelah proses pelatihan selesai, model dievaluasi menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) sebagaimana ditampilkan pada Gambar 2.

==== EVALUASI MODEL ====
ANN Standar:
MAE: 0.016403
RMSE: 0.022580

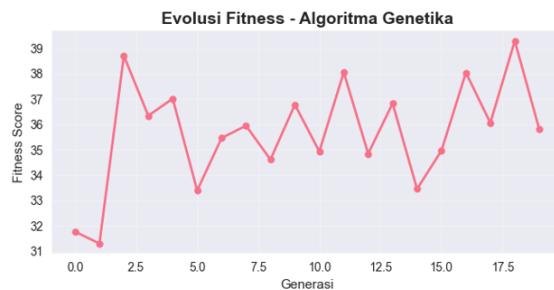
Gambar 2. Evaluasi Model ANN

Pada Gambar 2, model ANN standar menghasilkan nilai MAE sebesar 0.016403 dan RMSE sebesar 0.022580. Nilai ini menunjukkan bahwa model memiliki kemampuan awal yang cukup baik dalam memprediksi kejadian banjir berdasarkan data cuaca harian, meskipun masih terdapat ruang untuk peningkatan akurasi melalui proses optimasi lebih lanjut.

3.2. Hasil Optimasi Model dengan Algoritma Genetika

Setelah membangun model *Artificial Neural Network* (ANN) dengan konfigurasi standar, langkah selanjutnya adalah melakukan optimasi hyperparameter menggunakan Algoritma Genetika (AG). Tujuan dari tahap ini adalah untuk menemukan konfigurasi terbaik dari model ANN agar dapat menghasilkan prediksi banjir yang lebih akurat.

Optimasi dilakukan selama 20 generasi, dengan populasi awal terdiri dari beragam individu yang merepresentasikan kombinasi *hyperparameter* berbeda seperti jumlah neuron, *dropout rate*, *batch size*, dan *learning rate*. Setiap individu dievaluasi menggunakan fungsi fitness berdasarkan kombinasi nilai *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) dari hasil prediksi model tersebut. Hasil proses evolusi *fitness* ditunjukkan pada Gambar 3.



Gambar 3. Evolusi Fitness – AG

Pada Gambar 3, yang memperlihatkan fluktuasi nilai *fitness* dari generasi ke generasi. Terlihat bahwa nilai *fitness* meningkat secara umum seiring bertambahnya generasi, meskipun terdapat beberapa fluktuasi lokal. Kenaikan ini menunjukkan bahwa proses seleksi, *crossover*, dan mutasi dalam Algoritma Genetika berhasil mengeksplorasi ruang solusi dan menemukan konfigurasi ANN yang lebih optimal.

Setelah proses evolusi selesai, model dievaluasi menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) sebagaimana ditampilkan pada Gambar 4.

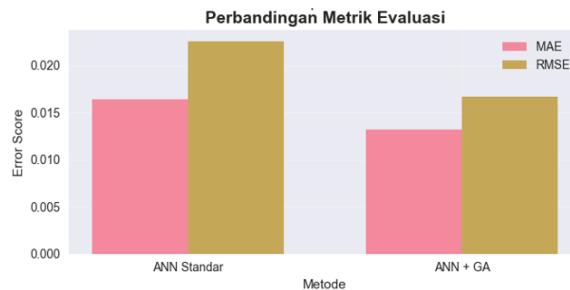
ANN + Algoritma Genetika:
MAE: 0.013183
RMSE: 0.016639

Gambar 4. Evaluasi Model ANN + Algoritma Genetika

Pada Gambar 4. Nilai ini lebih rendah dibandingkan dengan model baseline tanpa optimasi, yang memiliki MAE sebesar 0.013183 dan RMSE sebesar 0.016639. Penurunan nilai error tersebut menunjukkan bahwa integrasi ANN dengan Algoritma Genetika secara signifikan meningkatkan akurasi prediksi banjir.

3.3. Pembahasan

Hasil penelitian menunjukkan bahwa integrasi *Artificial Neural Network* (ANN) dengan Algoritma Genetika memberikan peningkatan performa yang signifikan dibandingkan dengan model ANN standar tanpa optimasi. Hal ini ditunjukkan secara kuantitatif melalui nilai error yang lebih rendah pada model ANN+AG, baik dalam metrik Mean Absolute Error (MAE) maupun Root Mean Squared Error (RMSE). Perbandingan hasil evaluasi antara kedua model ditampilkan pada Gambar 5.



Gambar 5. Perbandingan Metrik Evaluasi

Pada Gambar 5, yang memperlihatkan bahwa model ANN standar menghasilkan MAE sebesar 0.016403 dan RMSE sebesar 0.022580, sementara model ANN yang dioptimasi dengan GA menghasilkan MAE sebesar 0.013183 dan RMSE sebesar 0.016639. Penurunan nilai error ini menunjukkan bahwa model hasil optimasi lebih akurat dalam mengenali pola-pola yang berkaitan dengan potensi kejadian banjir.

Untuk menggambarkan seberapa besar peningkatan performa yang berhasil dicapai ditunjukkan pada gambar 6.

```
==== EVALUASI MODEL ====
ANN Standar:
MAE: 0.016403
RMSE: 0.022580

ANN + Algoritma Genetika:
MAE: 0.013183
RMSE: 0.016639

Peningkatan performa:
MAE: 19.63% lebih baik
RMSE: 26.31% lebih baik
```

Gambar 6. Perbandingan dan peningkatan performa nilai MAE dan RMSE

Pada Gambar 6, menunjukkan peningkatan performa dalam bentuk persentase. Model ANN yang dioptimasi menggunakan Algoritma Genetika menunjukkan peningkatan performa sebesar 19,63% pada MAE dan 26,31% pada RMSE. Ini membuktikan bahwa proses optimasi hyperparameter menggunakan pendekatan evolusioner seperti AG dapat membantu meningkatkan efisiensi pemodelan secara signifikan.

penurunan nilai MAE mengindikasikan bahwa secara rata-rata, selisih antara hasil prediksi dengan nilai aktual menjadi lebih kecil, artinya model ANN-AG mampu memberikan estimasi yang lebih dekat terhadap kondisi sebenarnya. Sementara itu, penurunan nilai RMSE memperlihatkan bahwa model juga semakin andal dalam menghindari kesalahan prediksi yang ekstrem atau outlier, karena RMSE lebih sensitif terhadap nilai-nilai error yang besar.

Selain itu, grafik evolusi *fitness* selama proses optimasi memperlihatkan tren peningkatan nilai fitness dari generasi ke generasi, yang menunjukkan bahwa proses seleksi dan mutasi dalam Algoritma Genetika efektif dalam mengarahkan pencarian ke solusi parameter yang optimal. Peningkatan akurasi ini diperoleh tanpa perlu menggunakan data tambahan, hanya dengan mengatur konfigurasi model secara sistematis melalui pendekatan evolusioner.

Secara keseluruhan, hasil ini menunjukkan bahwa kombinasi ANN dan Algoritma Genetika dapat menghasilkan model prediktif yang lebih presisi, efisien, dan adaptif, terutama dalam konteks pemodelan fenomena kompleks seperti prediksi banjir yang melibatkan banyak variabel lingkungan dan cuaca. Meskipun cakupan data terbatas

pada wilayah tertentu dan kurun waktu tertentu, pendekatan ini memberikan fondasi yang kuat untuk pengembangan sistem prediksi yang lebih luas dan dapat ditingkatkan skalanya di masa depan.

4. Kesimpulan

Penelitian ini membuktikan bahwa integrasi antara *Artificial Neural Network* (ANN) dan Algoritma Genetika (AG) mampu meningkatkan akurasi dalam prediksi bencana banjir di Kota Tegal. Model ANN standar yang dibangun telah menunjukkan kemampuan awal yang cukup baik dalam mengenali pola cuaca yang berkaitan dengan kejadian banjir. Namun, setelah dilakukan optimasi *hyperparameter* menggunakan AG, performa model meningkat secara signifikan, yang ditunjukkan dengan penurunan nilai MAE sebesar 19,63% dan RMSE sebesar 26,31%. Temuan ini menunjukkan bahwa pendekatan *hibrida* ANN-AG tidak hanya efektif dalam menangani data cuaca yang kompleks dan *non-linier*, tetapi juga mampu menghasilkan model prediktif yang lebih presisi dan adaptif. Implikasi dari hasil ini adalah terbukanya peluang penerapan sistem prediksi banjir yang lebih akurat sebagai alat bantu mitigasi bencana oleh pemerintah daerah dan lembaga terkait. Model yang dikembangkan dapat diperluas dan diadaptasi untuk wilayah lain dengan karakteristik data serupa, serta ditingkatkan skalanya dengan penambahan variabel lingkungan lain seperti pasang surut air laut dan tutupan lahan. Penelitian lebih lanjut disarankan untuk mengeksplorasi integrasi metode prediktif lainnya, seperti *Long Short-Term Memory* (LSTM) atau *ensemble learning*, guna lebih meningkatkan kemampuan model dalam menangani data sekuensial dan prediksi jangka panjang.

Referensi

- [1] J. Budhiana and J. Budhiana, "Pengaruh Karakteristik Responden Terhadap Kesiapsiagaan Bencana Banjir Di Desa Pasawahan Wilayah Kerja Puskesmas Cicurug Kabupaten Sukabumi," *J. Kesehat. Kusuma Husada*, vol. 15, no. 1, pp. 71–85, 2024, doi: 10.34035/jk.v15i1.1243.
- [2] A. A. Egaputra, D. H. Ismunarti, and W. S. Pranowo, "Inventarisasi Kejadian Banjir Rob Kota Semarang Periode 2012 - 2020," *Indones. J. Oceanogr.*, vol. 4, no. 2, pp. 29–40, 2022, doi: 10.14710/ijoce.v4i2.13240.
- [3] D. B. Saputro, A. Nurdin, and K. Amiroh, "Flood Early Warning System Using River Water Level Prediction with Artificial Neural Network (Case Study: Jakarta City)," in 2022 IEEE 8th Information Technology International Seminar (ITIS), 2022, pp. 252–256. doi: 10.1109/ITIS57155.2022.10010313.
- [4] S. Sandiwarno, "Penerapan Machine Learning Untuk Prediksi Bencana Banjir," *J. Sist. Inf. Bisnis*, vol. 14, no. 1, pp. 62–76, 2024, doi: 10.21456/vol14iss1pp62-76.
- [5] A. R. A. Brandão, D. Schwamback, F. C. M. de Menezes Filho, P. T. S. Oliveira, and M. C. Fava, "Artificial Neural Networks for Flood Prediction in Current and CMIP6 Climate Change Scenarios," *J. Flood Risk Manag.*, vol. 18, no. 1, 2025, doi: 10.1111/jfr3.70029.
- [6] Y. Cohen et al., "Recent Advances at the Interface of Neuroscience and Artificial Neural Networks," vol. 42, no. 45, pp. 8514–8523, 2022, doi: <https://doi.org/10.1523/JNEUROSCI.1503-22.2022>.
- [7] A. Review, "Electronics-10-02689-V2.Pdf," no. MI, 2021, doi: <https://doi.org/10.3390/electronics10212689>.
- [8] S. Mondal, R. Maity, and A. Nag, "An efficient artificial neural network-based optimization techniques for the early prediction of coronary heart disease: comprehensive analysis," *Sci. Rep.*, vol. 15, no. 1, pp. 1–24, 2025, doi: 10.1038/s41598-025-85765-x.
- [9] E. Egrioglu, C. Grosan, and E. Bas, "A new genetic algorithm method based on statistical-based replacement for the training of multiplicative neuron model artificial neural networks," *J. Supercomput.*, vol. 79, no. 7, pp. 7286–7304, 2023, doi: 10.1007/s11227-022-04935-0.
- [10] S. Lee, J. Kim, H. Kang, D. Y. Kang, and J. Park, "Genetic algorithm based deep learning neural network structure and hyperparameter optimization," *Appl. Sci.*, vol. 11, no. 2, pp. 1–12, 2021, doi: 10.3390/app11020744.
- [11] P. Studi, T. Mekatronika, J. T. Elektro, and P. N. Batam, "Prediksi Banjir Menggunakan Artificial Neural Network Tugas Akhir," no. 4212001048, 2025, doi: <https://repository.polibatam.ac.id/handle/PL029/3818>.
- [12] H. Zhu, J. Leandro, and Q. Lin, "Optimization of artificial neural network (Ann) for maximum flood inundation forecasts," *Water (Switzerland)*, vol. 13, no. 16, pp. 1–15, 2021, doi: 10.3390/w13162252.
- [13] R. M. A. Ikram, M. Wang, H. Moayedi, and A. A. Dehrashid, "Management and prediction of river flood utilizing optimization approach of artificial intelligence evolutionary algorithms," *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-04290-z.
- [14] V. Atashi and H. T. Gorji, "Enhanced flood prediction using LSTM and climate parameters: multi-station analysis of snowmelt-induced flooding in the Red River of the North," *J. Hydroinformatics*, vol. 27, no. 2, pp. 245–260, 2025, doi: 10.2166/hydro.2025.236.

- [15] M. F. Ghazali, A. Aqzela, C. Gracia, R. S. Febriningtyas, and D. Wijayanti, "Analisis Geospasial Kasus Stunting menggunakan Artificial Neural Network (ANN) di Kecamatan Gadingrejo, Pringsewu-Lampung," Maj. Geogr. Indones., vol. 37, no. 1, p. 1, 2022, doi: 10.22146/mgi.70474.
- [16] Rais, O. Somantri, I. Afriliana, E. Budihartono, and M. Khambali, "An optimized model for classification of appropriate technology products using neural networks and genetic algorithms," J. Phys. Conf. Ser., vol. 1430, no. 1, 2020, doi: 10.1088/1742-6596/1430/1/012035.
- [17] G. Gunawan, M. Miftakhudin, and Z. Arif, "Application of artificial neural network with optimization of genetic algorithms for weather prediction," J. Mantik, vol. 8, no. 1, pp. 758–767, 2024, doi: 10.35335/mantik.v8i1.5225.