



Penerapan Deep Neural Investigation Network (DNIN) Dengan Feature Selection Untuk Prediksi Bencana Banjir

Fachrul Ilmawan*, Yuhandri, Sumijan

Fakultas Ilmu Komputer, Magister Teknik Informatika, Universitas Putra Indonesia YPTK Padang, Padang, Indonesia

Jl. Raya Lubuk Begalung, Padang, 25221, Indonesia

Email: ^{1,*}fachrul.ilmawan@gmail.com, ²yuyu@upiypk.ac.id, ³soe@upiypk.org

Email Penulis Korespondensi : fachrul.ilmawan@gmail.com

Submitted: 31/01/2026; Accepted: 30/04/2026; Published: 30/04/2026

Abstrak—Banjir merupakan bencana alam yang disebabkan oleh tingginya intensitas hujan dan tidak baiknya daya serap yang terjadi disuatu daerah. Dampak dari banjir mengakibatkan korban material maupun korban jiwa sehingga diperlukannya proses mitigasi pencegahan bencana banjir. Berdasarkan hal tersebut maka tujuan penelitian ini memperdiksi bencana bajir dengan konsep Deep Learning (DL) menggunakan metode Deep Neural Investigation Network (DNIN) yang merupakan hybrid CNN–BiLSTM . Metode penelitian yang digunakan meliputi Deep Neural Investigation Network (DNIN) yang dipadukan dengan feature selection untuk memprediksi banjir. Feature selection dilakukan menggunakan metode SelectKBest dengan fungsi evaluasi ANOVA F-test (f_{classif}) untuk memilih fitur yang memiliki pengaruh paling signifikan terhadap variabel target banjir. Cara kerja DNIN mengekstraksi fitur dari data input dan memproses urutan fitur tersebut untuk menangkap dependensi temporal dua arah sebelum digunakan untuk prediksi. Dataset penelitian ini berjumlah 3000 baris data yang bersuber dari Kaggle (<https://www.kaggle.com/datasets/yusufginanjar7/banjir-jabodetabek>) dengan field name_2, name_3, avg_rainfall, max_rainfall, avg_temperature, elevation, landcover_class, ndvi, slope, soil_moisture, year, month banjir, lat long. Hasil Penelitian ini telah membuktikan penerapan metode Deep Neural Investigation Network (DNIN) dengan fitur selection mampu untuk memprediksi banjir. Hasil penelitian menunjukkan bahwa penerapan metode DNIN dengan feature selection mampu memprediksi bencana banjir dengan tingkat akurasi sebesar 93%. Berdasarkan hasil penelitian ini penerapan metode Deep Neural Investigation Network (DNIN) dengan feature selection mampu memberikan kontribusi yang signifikan dalam memprediksi terjadinya bencana banjir secara akurat serta dapat dimanfaatkan sebagai sistem pendukung pengambilan keputusan dalam upaya mitigasi dan pengurangan risiko bencana banjir.

Kata Kunci: Prediksi Banjir; Deep Learning; Deep Neural Investigation Network (DNIN); Seleksi Fitur; Mitigasi Bencana

Abstract—Floods are natural disasters caused by high rainfall intensity and poor absorption capacity in an area. The impact of floods results in material and human casualties, necessitating a flood disaster mitigation process. Based on this, the purpose of this study is to predict flood disasters with the Deep Learning (DL) concept using the Deep Neural Investigation Network (DNIN) method, which is a CNN–BiLSTM hybrid. The research method used includes Deep Neural Investigation Network (DNIN) combined with feature selection to predict floods. Feature selection is carried out using the SelectKBest method with the ANOVA F-test (f_{classif}) evaluation function to select features that have the most significant influence on the target flood variable. The DNIN method extracts features from input data and processes the sequence of these features to capture two-way temporal dependencies before being used for prediction. This research dataset consists of 3000 rows of data sourced from Kaggle (<https://www.kaggle.com/datasets/yusufginanjar7/banjir-jabodetabek>) with fields name_2, name_3, avg_rainfall, max_rainfall, avg_temperature, elevation, landcover_class, ndvi, slope, soil_moisture, year, month banjir, lat long. The results of this study have proven the application of the Deep Neural Investigation Network (DNIN) method with feature selection is able to predict floods. The results show that the application of the DNIN method with feature selection is able to predict flood disasters with an accuracy level of 93%. Based on the results of this study, the application of the Deep Neural Investigation Network (DNIN) method with feature selection is able to provide a significant contribution in predicting flood disasters accurately and can be used as a decision support system in flood disaster risk mitigation and reduction efforts.

Keywords: Flood Prediction; Deep Learning; Deep Neural Investigation Network (DNIN); Feature Selection; Disaster Mitigation

1. PENDAHULUAN

Banjir merupakan bencana alam yang sulit diprediksi karena dapat terjadi secara tiba-tiba dengan tingkat keparahan yang tidak menentu, kecuali pada wilayah yang sering mengalaminya, dan dipengaruhi oleh berbagai faktor seperti kemiringan lereng dan ketinggian wilayah, jenis serta penggunaan lahan, kerapatan sungai, serta curah hujan yang tinggi [1]. Banjir dapat terjadi ketika wilayah yang umumnya kering tergenang akibat curah hujan tinggi pada daerah bertopografi dataran rendah yang cekung serta ketika debit air yang meningkat secara terus-menerus melebihi kapasitas sistem aliran sungai, sehingga menyebabkan luapan air ke wilayah sekitarnya [2].

Penelitian dengan memanfaatkan pendekatan machine learning dan deep learning untuk mengklasifikasikan tingkat risiko banjir di Indonesia berdasarkan variabel lingkungan dan sosial, dan menunjukkan bahwa model deep learning mampu meningkatkan akurasi prediksi risiko banjir [3]. Penelitian lain menggunakan arsitektur deep learning berbasis CNN dan BiLSTM dalam model *Deep Neural Investigation Network (DNIN)* untuk menangkap pola spasial dan temporal dari data curah hujan sehingga efektif dalam memprediksi kejadian banjir dan mendukung sistem peringatan dini . Studi ini membandingkan performa model LSTM dan gabungan *deep learning CNN-LSTM* dalam meramalkan curah hujan harian, suatu parameter penting dalam prediksi banjir di wilayah tropis [4]. Machine Learning (ML) dapat dikategorikan menjadi empat



pendekatan utama, yaitu Supervised Learning, Unsupervised Learning, Semi-Supervised Learning, dan Reinforcement Learning. Masing-masing kategori memiliki metode, karakteristik, dan aplikasi yang berbeda [5]

Deep Learning merupakan cabang dari *Machine Learning* yang menerapkan arsitektur jaringan saraf tiruan berlapis (*deep neural networks*) untuk mempelajari representasi data secara otomatis melalui transformasi non-linear di tiap lapisan [6]. Keunggulan utama *Deep Learning* adalah kemampuannya mengekstraksi fitur kompleks dari data mentah tanpa memerlukan rekayasa fitur manual, sehingga sangat relevan untuk menangani data besar (*big data*) dan tidak terstruktur seperti citra, teks, maupun deret waktu [7]. Penelitian yang dilakukan oleh Irawan (2025) mengombinasikan beberapa arsitektur *machine learning* dan *deep learning* untuk mengklasifikasikan tingkat risiko banjir berdasarkan variabel lingkungan dan sosial di Indonesia, serta menunjukkan bahwa model *deep learning* memiliki kinerja yang baik dalam klasifikasi risiko banjir [8]. Penelitian lain mengembangkan model *deep learning* untuk deteksi dini stroke otak dengan menggunakan citra medis dan menyajikan prediksi yang akurat untuk diagnosis medis [9].

DNIN menggabungkan dua metode utama dalam *deep learning* yaitu *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BiLSTM)*, sehingga mampu memanfaatkan keunggulan masing-masing dalam mengenali pola kompleks yang tersembunyi dalam data. *CNN* berperan mengekstraksi fitur spasial dari data, misalnya distribusi curah hujan, tinggi muka air, dan kondisi geografis sungai, sedangkan *BiLSTM* menangkap dependensi temporal pada urutan kejadian, sehingga tren historis dapat dianalisis untuk prediksi yang lebih akurat [10]. Kombinasi *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BiLSTM)* merupakan arsitektur *deep learning* yang mampu mengekstraksi pola spasial dan ketergantungan temporal dua arah secara simultan, sehingga efektif digunakan untuk memodelkan dan memprediksi data runtun waktu yang kompleks seperti curah hujan dan banjir [11]. Gabungan antara *CNN* dan model temporal, seperti *LSTM* atau *Bidirectional LSTM*, memungkinkan penanganan data deret waktu seperti curah hujan harian atau tinggi muka air secara efektif [12]. Prediksi dilakukan dengan cara membangun model dari dataset pelatihan (*training data*) untuk kemudian digunakan dalam memperkirakan output pada dataset baru [13].

Penelitian terdahulu telah banyak menerapkan berbagai metode dalam upaya prediksi bencana banjir. Penelitian dengan judul penerapan *machine learning* untuk prediksi banjir dengan membandingkan metode *Support Vector Machine (SVM)*, *K-Nearest Neighbor (KNN)*, *Naive Bayes*, *Bidirectional Long Short-Term Memory (BiLSTM)*, *Convolutional Neural Network (CNN)* dan *Deep Neural Investigation Network (DNIN)*. Hasil yang diperoleh *Deep Neural Investigation Network (DNIN)* lebih akurat dengan nilai akurasi 0.9496, *precision* 0.9346, *Recall* 0.9833, *F1-score* 0.9547, *AUC* 0.9804 dan *ROC* 0.99 [9]. Penelitian dengan judul deteksi emosi berdasarkan wicara menggunakan *deep learning* model. Dalam penelitian ini peneliti membandingkan algoritma *Convolutional Neural Network (CNN)* - *Bidirectional Long Short-Term Memory (BiLSTM)*, dan *Convolutional Neural Network (CNN)* - *Bidirectional Gated Recurrent Unit (BiGRU)*. Hasil yang diperoleh akurasi tertinggi yaitu 91,29% didapatkan dengan menggabungkan model *CNN* dan *Bidirectional Long Short-Term Memory (BiLSTM)* [14]. Perbedaan hasil akurasi dengan penelitian ini adalah dari dataset yang digunakan, pada penelitian ini menggunakan dataset berbeda.

Convolutional Neural Network (CNN) adalah jenis arsitektur *Deep Learning* yang dirancang untuk secara efektif memproses data berdimensi tinggi, seperti citra atau citra satelit, melalui struktur hierarkis yang mengedepankan ekstraksi fitur spasial secara otomatis dan efisien. *CNN* meniru prinsip kerja sistem penglihatan biologis mengidentifikasi fitur dari pola sederhana hingga kompleks lewat lapisan-lapisan konvolusi [15]. *CNN* merupakan arsitektur *deep learning* berbasis jaringan saraf feed forward yang dikembangkan dari *multilayer perceptron (MLP)* dan dirancang untuk mengolah data [16]. Penelitian arrahman (2024) menggunakan metode *CNN* dapat melakukan klasifikasi dengan akurasi 0.9905 dengan menunjukkan kesesuaian prediksi berdasarkan kelas dengan *classification report*, nilai *recall*, *precision* dan *f1-score* yang bagus [17].

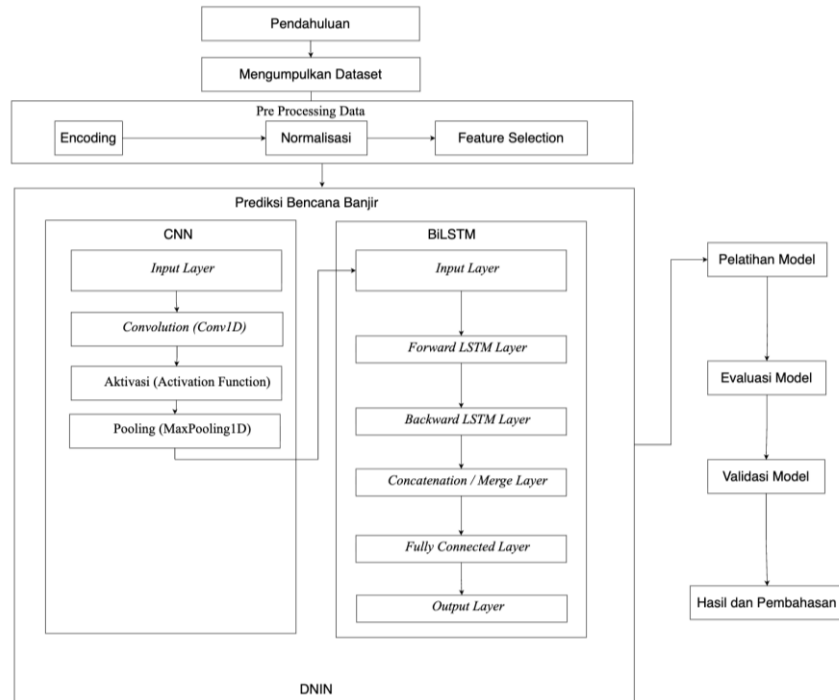
Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari arsitektur *Long Short-Term Memory (LSTM)* yang dirancang untuk mengatasi masalah *long-term dependency* pada data sekuensial. *LSTM* sendiri menggunakan *gates* (*input*, *forget* dan *output*) untuk mengontrol aliran informasi, sehingga mampu menyimpan dan melupakan informasi sesuai kebutuhan. Pada *BiLSTM*, jaringan *LSTM* dioperasikan dalam dua arah, maju (*forward*) dan mundur (*backward*), memungkinkan model untuk memanfaatkan informasi dari konteks masa lalu dan masa depan secara bersamaan [18]. Hasil penelitian menunjukkan bahwa pendekatan *BiLSTM* dapat meningkatkan akurasi prediksi pola curah hujan harian dibandingkan *LSTM* konvensional, sehingga memberikan kontribusi dalam sistem peringatan dini banjir [19]. Penelitian Prediksi Curah Hujan Menggunakan Metode *BiLSTM* dan *GRU* Berbasis Data Iklim menunjukkan bahwa model *BiLSTM* memberikan performa prediksi yang lebih stabil dan akurat dibandingkan *GRU* dalam memodelkan curah hujan di wilayah beriklim tropis, yang dapat mendukung mitigasi banjir akibat curah hujan ekstrem [20].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan dan menguji model prediksi bencana banjir berbasis *Deep Neural Investigation Network (DNIN)* yang dipadukan

dengan teknik *feature selection*. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan data, pemilihan fitur relevan dan pelatihan model *DNIN* serta evaluasi kinerja model.




Gambar 1. Kerangka Penelitian

Kerangka penelitian pada gambar 1. dalam prediksi bencana banjir yang diawali dari tahap pendahuluan hingga pengolahan data dan pemodelan. Proses dimulai dengan pengumpulan *dataset* yang relevan, kemudian dilakukan tahap pra-pemrosesan data yang meliputi *encoding* untuk mengubah data kategorikal menjadi numerik, normalisasi untuk menyamakan skala data, serta *feature selection* untuk memilih atribut yang paling berpengaruh terhadap hasil prediksi. Tahapan ini bertujuan untuk meningkatkan kualitas data sehingga model dapat belajar secara lebih efektif dan mengurangi noise yang dapat menurunkan akurasi prediksi.

Data yang telah diproses digunakan dalam arsitektur *Deep Neural Network (DNIN)* yang menggabungkan *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BLSTM)*. *CNN* berfungsi mengekstraksi pola penting dari data melalui proses konvolusi, aktivasi, dan pooling, sedangkan *BLSTM* menangkap hubungan temporal secara dua arah melalui *forward* dan *backward LSTM*. Hasil dari kedua model kemudian digabungkan melalui layer *concatenation* sebelum diteruskan ke *fully connected layer* dan *output layer* untuk menghasilkan prediksi. Proses ini diakhiri dengan tahapan pelatihan, evaluasi, dan validasi model guna memastikan performa yang optimal, sebelum akhirnya dianalisis pada bagian hasil dan pembahasan.

2.2 Deep Neural Investigation Network (DNIN)

Arsitektur dalam *Deep Neural Investigation Network (DNIN)* dimulai dengan melakukan preprocessing pada dataset, termasuk pembersihan, encoding, normalisasi, dan reshape agar data siap diproses oleh model. Setelah itu, *CNN-ID* mengekstraksi pola lokal dari data dan outputnya diteruskan ke *BiLSTM* yang mempelajari hubungan jangka panjang dari dua arah sekaligus. Terakhir, hasil *BiLSTM* diproses oleh *fully connected layer* dan aktivasi sigmoid untuk menghasilkan keputusan klasifikasi akhir [9]:



Gambar 2. Arsitektur *Deep Neural Investigation Network (DNIN)*

Gambar 2 menggambarkan sebuah hybrid model yang menggabungkan *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BiLSTM)* dalam satu rancangan untuk memproses data berurutan. Pendekatan ini diharapkan mampu meningkatkan performa pada tugas klasifikasi biner melalui model yang disebut *Deep Neural Investigation Network (DNIN)*. Pada penelitian ini, bagian *CNN* terdiri atas *convolution layer* dan *fully connected layer*. *CNN* mengekstraksi representasi fitur dari data *input* dengan memanfaatkan hubungan antar-lapisan untuk menentukan kelas. Setiap lapisan konvolusi menggunakan fungsi aktivasi *ReLU* untuk meniadakan nilai negatif dan mempertahankan nilai positif. Operasi konvolusi mengikuti persamaan [9]:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a) w(t - a) \tag{1}$$

Parameter $s(t)$ sebagai hasil konvolusi, x sebagai input, dan w sebagai bobot atau kernel. Pada *fully connected layer*, seluruh *neuron* dalam suatu lapisan terhubung ke semua *neuron* pada lapisan berikutnya sebagaimana pada jaringan saraf *multilayer perceptron (MLP)*. Fungsinya adalah mengubah dimensi fitur agar dapat diklasifikasikan secara linier. Berbeda dari *convolutional layer* yang hanya terhubung pada area input tertentu, *fully connected layer* bersifat terhubung penuh [9].

3. HASIL DAN PEMBAHASAN

Model *Deep Neural Investigation Network (DNIN)* yang menggabungkan arsitektur *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BiLSTM)* dalam memprediksi kejadian banjir. Proses penelitian diawali dengan tahapan *preprocessing* data yang bertujuan untuk meningkatkan kualitas input model, meliputi pembersihan data, normalisasi, serta pembagian *dataset* menjadi data latih dan data uji. Selanjutnya, model dilatih menggunakan data yang telah diproses untuk mempelajari pola-pola yang berkaitan dengan kejadian banjir berdasarkan parameter yang digunakan.

Hasil pelatihan model menunjukkan performa yang baik, yang ditunjukkan melalui nilai metrik evaluasi utama berupa akurasi, *precision*, *recall*, dan *F1-score*. Evaluasi menggunakan *confusion matrix* memberikan gambaran kemampuan model dalam membedakan antara kondisi banjir dan tidak banjir secara tepat, sekaligus mengidentifikasi kesalahan klasifikasi yang masih terjadi. Selain itu, visualisasi kurva akurasi dan loss selama proses *training* memperlihatkan *tren* konvergensi yang stabil, menandakan bahwa model mampu melakukan pembelajaran secara efektif tanpa indikasi *overfitting* yang signifikan. Berdasarkan hasil tersebut, dapat disimpulkan bahwa pendekatan *deep learning* menggunakan *DNIN* memiliki potensi yang kuat dalam mendukung sistem prediksi banjir yang akurat dan dapat dikembangkan lebih lanjut untuk implementasi di dunia nyata.

3.1 Preprocessing

Pra-pemrosesan data (*data preprocessing*) merupakan tahapan penting yang selalu dilakukan sebelum menerapkan algoritma seperti *Convolutional Neural Network (CNN)*, *Bidirectional Long Short-Term Memory (BiLSTM)*, maupun *Deep Neural Investigation Network (DNIN)*. Tahapan ini bertujuan untuk mengubah data mentah menjadi format yang siap digunakan dalam proses pembelajaran mesin.

Dalam penelitian ini, tahapan pra-pemrosesan meliputi beberapa langkah utama, yaitu *cleansing*, *normalisasi*, *reshape*, *selection Feature* serta pembagian data (*split*). Proses *cleansing* dilakukan untuk membersihkan data dari nilai hilang atau tidak konsisten. *Encoding* diterapkan agar variabel kategorikal dapat diubah ke bentuk numerik. Normalisasi dilakukan untuk menyeragamkan skala data agar setiap parameter memiliki kontribusi yang seimbang. Tahap *reshape* digunakan untuk menyesuaikan dimensi data dengan kebutuhan arsitektur model. Sementara itu, pembagian data dilakukan untuk memisahkan data latih (*training set*) dan data uji (*testing set*) sehingga performa model dapat dievaluasi secara objektif. *Feature selection* dilakukan menggunakan metode *SelectKBest* dengan fungsi evaluasi ANOVA F-test (*f_classif*) untuk memilih fitur yang memiliki pengaruh paling signifikan terhadap variabel target banjir. *SelectKBest* bekerja dengan memberikan skor pada setiap fitur berdasarkan tingkat relevansinya terhadap target klasifikasi, nilai *K* yang digunakan $K=7$.

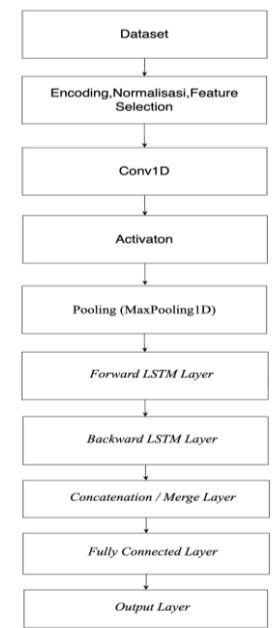
Tabel 1. Hasil Preprocessing

Avg_Rainfall	Max_Rainfall	Avg_Temperature	Elevation	Ndvi	Slope	Soil_Moisture	Banjir
0.22243138	0.22791153	0.57030512	0.135088219	0.74999999	0.205469783	0.94676488	
8090756	139066697	73985531	44880836	99999998	8553154	45686513	1
0.29413725	0.37929488	0.52658068	0.174233756	0.91542288	0.572474636	0.83676336	
083991604	73596832	5750236	03601676	55721391	0829289	57351156	1
0.30856218	0.33317145	0.87260144	0.005015194	0.15422885	0.003705337	0.79529921	
98165245	92944604	69959105	467680808	5721393	450374945	02065614	0
0.20678598	0.21077333	0.58697703	0.045151087	0.67910447	0.174503749	0.71996506	
128315756	98794483	68040264	2136528	76119401	4486105	68286756	1

Berdasarkan Tabel 1, dapat dilihat bahwa seluruh variabel numerik telah berhasil ditransformasikan ke dalam rentang nilai terstandarisasi antara 0 dan 1 melalui proses normalisasi, sehingga perbedaan skala antarfitur seperti curah hujan, suhu, elevasi, dan kelembapan tanah tidak lagi mendominasi proses pembelajaran model. Nilai pada setiap kolom menunjukkan bahwa data telah bersih dari nilai kosong serta siap digunakan sebagai input model berbasis *deep learning* yang sensitif terhadap skala data. Sementara itu, variabel target Banjir tetap dipertahankan dalam bentuk biner (0 dan 1) untuk merepresentasikan kondisi tidak banjir dan banjir. Hasil pra-pemrosesan ini memastikan bahwa data memiliki kualitas yang baik, konsisten, serta kompatibel dengan arsitektur *CNN*, *BiLSTM* dan *DNIN*, sehingga dapat meningkatkan stabilitas pelatihan dan akurasi prediksi model.

3.2 Analisis Deep Neural Investigation Network (DNIN)

Deep Neural Investigation Network (DNIN) merupakan salah satu arsitektur jaringan saraf dalam (*deep neural network*) yang dirancang khusus untuk menangani data kompleks dengan dimensi spasial dan temporal secara simultan. *DNIN* menggabungkan dua metode utama dalam *deep learning*, yaitu *Convolutional Neural Network (CNN)* dan *Bidirectional Long Short-Term Memory (BiLSTM)*, sehingga mampu memanfaatkan keunggulan masing-masing dalam mengenali pola kompleks yang tersembunyi dalam data. Algoritma *DNIN* pada Gambar 2.



Gambar 3. Metode *DNIN* Dengan *Feature Selection*

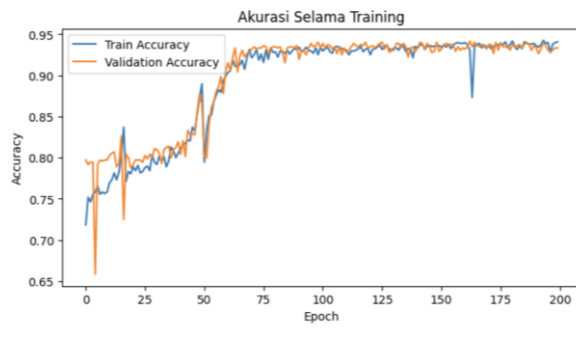
Gambar 3 menunjukkan arsitektur model *DNIN* yang digunakan dalam proses prediksi bencana banjir, yang terdiri dari tiga komponen utama *CNN* dan *BiLSTM*. Pada tahap pertama, lapisan *CNN-1D* berfungsi mengekstraksi pola lokal dari data masukan sehingga menghasilkan representasi fitur yang lebih informatif. Hasil ekstraksi tersebut kemudian diteruskan ke lapisan *BiLSTM* yang mampu mempelajari hubungan jangka panjang dari dua arah sekaligus sehingga konteks data dapat dipahami secara lebih komprehensif. Terakhir, *output BiLSTM* diproses oleh *Fully Connected Layer* untuk menghasilkan keputusan klasifikasi akhir terkait potensi terjadinya banjir. Arsitektur ini dirancang untuk menggabungkan kekuatan ekstraksi fitur *CNN* dan kemampuan pemahaman urutan *BiLSTM* dalam satu model prediksi yang lebih akurat dan efektif.

Model *Deep Neural Investigation Network (DNIN)* mampu mengintegrasikan kekuatan *CNN* dan *BiLSTM* secara efektif dalam memprediksi bencana banjir. *CNN* melalui *Conv1D*, aktivasi *ReLU*, dan *MaxPooling1D* berhasil mengekstraksi serta mereduksi fitur penting dari data deret waktu sehingga menghasilkan representasi yang lebih informatif dan stabil. Selanjutnya, *BiLSTM* memproses fitur tersebut dari dua arah waktu (*forward* dan *backward*), memungkinkan model menangkap pola temporal jangka pendek maupun jangka panjang secara lebih komprehensif. Proses *concatenation* menggabungkan konteks dua arah ini menjadi satu vektor fitur yang kaya sebelum diteruskan ke *fully connected layer* untuk pengambilan keputusan akhir. Hasil *output* model berupa probabilitas banjir menunjukkan bahwa *DNIN* mampu membedakan kondisi banjir dan tidak banjir dengan baik berdasarkan ambang batas klasifikasi. Perbandingan antara nilai prediksi dan target aktual memperlihatkan performa yang konsisten dalam mengklasifikasikan data uji, menandakan bahwa arsitektur ini efektif dalam mempelajari pola kompleks pada data hidrologi. Secara keseluruhan, penerapan *DNIN* terbukti mampu meningkatkan akurasi prediksi banjir melalui kombinasi ekstraksi fitur spasial oleh *CNN* dan pemahaman sekuen temporal oleh *BiLSTM*, sehingga layak digunakan sebagai model pendukung mitigasi dan pengambilan keputusan dalam penanggulangan bencana banjir. Hasil pelatihan model yang diperoleh dari proses eksperimen, meliputi nilai *training loss*, *validation loss* serta akurasi pada data pelatihan dan validasi sebagai indikator kinerja model dalam melakukan prediksi tersaji pada Tabel 2.

Tabel 2. Hasil Predit pada *Data Training*

Epoch	Train Loss	Val Loss	Train Accuracy	Val Accuracy
1	0,541845679	0,470552802	0,740104139	0,814583361
2	0,515242219	0,445114404	0,746874988	0,814583361
3	0,487949312	0,470234901	0,767708361	0,756250024
.....
68	0,349287868	0,337180257	0,849479139	0,850000024
69	0,356888175	0,33095035	0,838020861	0,850000024
70	0,351885915	0,34257549	0,848437488	0,837499976
71	0,350776643	0,344874293	0,839583337	0,841666639
72	0,345181286	0,328678817	0,844791651	0,841666639
73	0,350748956	0,354326874	0,844270825	0,835416675

Tabel 2 menampilkan ringkasan performa model selama proses pelatihan berdasarkan empat metrik utama, yaitu *train loss*, *validation loss*, *train accuracy* dan *validation accuracy* pada setiap *epoch*. Dari tabel tersebut terlihat bahwa nilai *train loss* dan *validation loss* secara umum cenderung menurun, yang menunjukkan bahwa model semakin mampu menyesuaikan parameter untuk mempelajari pola data dengan lebih baik. Di sisi lain, nilai akurasi baik pada data pelatihan maupun validasi mengalami peningkatan bertahap dan kemudian stabil pada rentang nilai yang cukup tinggi, khususnya setelah memasuki *epoch* ke-60. Konsistensi antara tren akurasi pelatihan dan validasi mengindikasikan bahwa model tidak mengalami penyimpangan signifikan antara data latih dan data uji, sehingga dapat disimpulkan bahwa proses pelatihan berjalan dengan stabil dan model memiliki kinerja generalisasi yang memadai.




Gambar 4. Akurasi Model Selama *Training* dengan Feature Selection

Gambar 4 menampilkan perkembangan akurasi model *DNIN* selama proses *training*. Garis biru merepresentasikan akurasi pada data latih, sementara garis oranye menunjukkan akurasi pada data validasi di setiap *epoch*. Pada awal proses *training*, terjadi peningkatan akurasi yang cukup signifikan karena model sedang belajar mengenali pola-pola utama dalam data, kemudian tren akurasi cenderung stabil dengan kenaikan yang lebih lambat seiring bertambahnya jumlah *epoch*.


Variasi garis oranye (*validation accuracy*) lebih besar dibandingkan garis biru karena data validasi digunakan untuk mengecek generalisasi model terhadap data yang belum pernah dilihat selama pelatihan. Kesetaraan yang cukup baik antara akurasi latih dan validasi pada grafik ini mengindikasikan bahwa model tidak mengalami *overfitting*, di mana performa pada data latih sangat tinggi tetapi buruk pada data validasi. Sebaliknya, model ini menunjukkan kemampuan generalisasi yang optimal sehingga prediksi terhadap data baru tetap baik.

Akurasi diangka 0.93 pada kedua data menunjukkan model *DNIN* berhasil membangun representasi fitur yang relevan selama pelatihan. Grafik ini juga menjadi panduan penting untuk mengevaluasi stabilitas proses *training* dan memilih model terbaik sebelum terjadinya *overfitting*. Dengan hasil ini, model yang diperoleh dapat diandalkan untuk proses klasifikasi pada aplikasi prediksi banjir secara nyata.




Gambar 5. Akurasi Model Selama *Training* tanpa Feature Selection

Gambar 5 Akurasi diangka 0.82 untuk model DNIN tanpa menggunakan feature selection. Hasil tersebut menunjukkan bahwa penerapan feature selection memberikan pengaruh signifikan dalam meningkatkan performa model klasifikasi. Dengan pemilihan fitur yang relevan, model mampu menghasilkan prediksi yang lebih akurat dan memiliki kemampuan generalisasi yang lebih baik.



Gambar 6. ROC Curve Testing dengan Feature Selection

Kurva ROC pada data pengujian menunjukkan bahwa model CNN-BiLSTM memiliki kemampuan klasifikasi yang sangat baik dengan nilai Area Under Curve (AUC) sebesar 0,9655, yang berada jauh di atas garis acak (*random classifier*). Bentuk kurva yang mendekati sudut kiri atas mengindikasikan tingkat sensitivitas yang tinggi dalam mendeteksi kejadian banjir disertai dengan tingkat kesalahan prediksi positif yang relatif rendah, sehingga model mampu membedakan kelas banjir dan tidak banjir secara efektif. Nilai AUC yang tinggi ini menegaskan bahwa model memiliki kemampuan generalisasi yang kuat terhadap data yang belum pernah dilatih sebelumnya, serta menunjukkan bahwa pendekatan *hybrid CNN-BiLSTM* mampu menangkap pola spasial dan temporal yang relevan dalam prediksi banjir secara akurat dan andal untuk keperluan analisis hidrologi.




Gambar 7. ROC Curve Testing tanpa Feature Selection

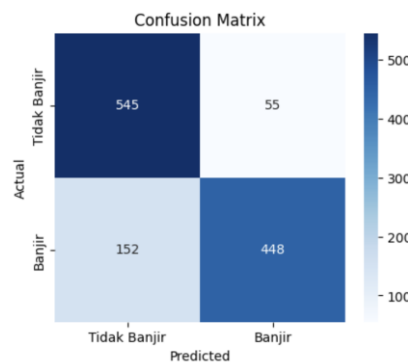
Gambar 7 menunjukkan performa pengujian model tanpa menggunakan feature selection yang menghasilkan nilai Area Under Curve (AUC) sebesar 0,9091. Angka ini lebih rendah dibandingkan dengan model yang menggunakan seleksi fitur pada Gambar 6, yang mengindikasikan kemampuan deteksi banjir yang sedikit lebih rendah dibandingkan dengan penggunaan feature selection.

3.3 Evaluasi

Evaluasi model bertujuan untuk mengukur dan menilai kinerja model dalam melakukan klasifikasi terhadap data uji yang belum pernah dilihat selama proses pelatihan. Pada studi ini, evaluasi dilakukan dengan menggunakan beberapa metrik klasik pada masalah klasifikasi biner, antara lain akurasi, *precision*, *recall*, dan *F1-score*. Metrik-metrik tersebut diperoleh dari perbandingan antara hasil prediksi model dan label sebenarnya pada data uji. Selain itu, visualisasi *confusion matrix* juga disajikan untuk memudahkan interpretasi performa model dalam mengenali empat kategori hasil prediksi: *True Positives* (benar memprediksi banjir), *True Negatives* (benar memprediksi tidak banjir), *False Positives* (kesalahan prediksi positif/banjir), dan *False Negatives* (kesalahan prediksi negatif/tidak banjir). Adapun hasil evaluasi proses prediksi dapat dilakukan dengan *confusion matrix* yang disajikan pada Gambar 5.

**Gambar 8.** Confusion Matrix dengan Feature Selection

Gambar 8 merupakan *visualisasi confusion matrix* di atas menggambarkan performa model dalam membedakan antara kelas "Tidak Banjir" dan "Banjir" berdasarkan hasil prediksi pada data uji. Setiap kotak pada matriks menunjukkan jumlah sampel hasil prediksi versus kenyataan, dengan sumbu vertikal (*Actual*) sebagai label asli dan sumbu horizontal (*Predicted*) sebagai hasil prediksi model. Berdasarkan hasil confusion matrix, model menunjukkan performa klasifikasi yang sangat baik dalam mendeteksi kondisi banjir dan tidak banjir. Model berhasil mengklasifikasikan 592 data tidak banjir dan 524 data banjir secara benar, dengan hanya 8 data tidak banjir yang salah diprediksi sebagai banjir (false positive) serta 76 data banjir yang salah diklasifikasikan sebagai tidak banjir (false negative).

**Gambar 9.** Confusion Matrix tanpa Feature Selection

Gambar 9 menyajikan confusion matrix hasil pengujian model tanpa feature selection yang merangkum ketepatan prediksi terhadap data aktual. Dalam visualisasi tersebut, model berhasil mengklasifikasikan secara benar sebanyak 545 data sebagai "Tidak Banjir" (true negative) dan 448 data sebagai "Banjir" (true positive). Namun demikian, terdapat kesalahan klasifikasi di mana 55 data "Tidak Banjir" diprediksi sebagai "Banjir" (false positive), serta 152 data "Banjir" yang keliru dikategorikan sebagai "Tidak Banjir" (false negative).

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan *Deep Neural Investigation Network (DNIN)* yang mengombinasikan arsitektur *CNN* dan *BiLSTM* serta dipadukan dengan teknik *feature selection* mampu memberikan performa yang baik dalam memprediksi kejadian banjir disbanding dengan tanpa feature selection. Dengan menggunakan DNIN dengan feature selection mendapatkan akurasi 93%. Untuk penelitian selanjutnya, disarankan melakukan lebih banyak percobaan atau eksperimen terhadap parameter dasar dengan dataset yang lebih besar dan parameter tuning dari model DNIN.

REFERENCES

- [1] M. Seprianto, M. Anggo, L. Harudu, and S. Aldiansyah, "Pemetaan Daerah Potensi Rawan Banjir Menggunakan Metode Overlay," vol. 9, no. 4, 2024.
- [2] M. Dwi Arvi, R. Sahanaya, Y. Sibarani, Y. I. Tanjung, and T. Fairuz, "Analisis Faktor Penyebab Bencana Banjir di Kota-Kota Besar Indonesia: Studi Kasus Analisis Banjir Berbasis Literasi," *ETCE*, vol. 3, no. 1, pp. 1-8, 2025, doi: 10.71383/ijetce.v3i1.70.
- [3] Y. Irawan, Refni Wahyuni, and Herianto, "An Integrated Machine Learning and Deep Learning Approach for Multiclass Flood Risk Classification with Feature Selection and Imbalanced Data Handling," *JURNAL TEKNOLOGI DAN OPEN SOURCE*, vol. 8, no. 2, pp. 650–661, Dec. 2025, doi: 10.36378/jtos.v8i2.4639.



- [4] D. Kota, T. Selatan Uliyatonisa, and D. Supriatna, “Komparasi Model LSTM dan CNN-LSTM untuk Peramalan Curah Hujan,” *Bulletin of Information Technology (BIT)*, vol. 6, no. 3, pp. 294–301, 2025, doi: 10.47065/bit.v5i2.2235.
- [5] Panji Bintoro, Ratnasari, Edy Wihardjo, Indah Pratiwi Putri, and Andi Asari, “Pengantar Machine Learning,” 2024.
- [6] M. Trigka and E. Dritsas, “A Comprehensive Survey of Deep Learning Approaches in Image Processing,” Jan. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/s25020531.
- [7] A. Mumuni and F. Mumuni, “Automated data processing and feature engineering for deep learning and big data applications: A survey,” *Journal of Information and Intelligence*, vol. 3, no. 2, pp. 113–153, Mar. 2025, doi: 10.1016/j.jiixd.2024.01.002.
- [8] Y. Irawan, Refni Wahyuni, and Herianto, “An Integrated Machine Learning and Deep Learning Approach for Multiclass Flood Risk Classification with Feature Selection and Imbalanced Data Handling,” *JURNAL TEKNOLOGI DAN OPEN SOURCE*, vol. 8, no. 2, pp. 650–661, Dec. 2025, doi: 10.36378/jtos.v8i2.4639.
- [9] A. Nur holifah and I. Tahyudin, “Implementasi Teknologi Deep Learning untuk Diagnostik Stroke Otak Berbasis CNN-LSTM-FNN,” *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 3, pp. 538–599, Mar. 2025, doi: 10.52436/1.jpti.538.
- [10] S. Sandiwarno, “Penerapan Machine Learning Untuk Prediksi Bencana Banjir,” *Jurnal Sistem Informasi Bisnis*, vol. 14, no. 1, pp. 62–76, Jan. 2024, doi: 10.21456/vol14iss1pp62-76.
- [11] M. Marjani, M. Mahdianpari, and F. Mohammadmanesh, “CNN-BiLSTM: A Novel Deep Learning Model for Near-Real-Time Daily Wildfire Spread Prediction,” *Remote Sens. (Basel)*, vol. 16, no. 8, Apr. 2024, doi: 10.3390/rs16081467.
- [12] N. Chenmin, M. F. Marsani, and F. P. Shan, “Flood prediction based on feature selection and a hybrid deep learning network,” *Journal of Water and Climate Change*, vol. 15, no. 3, pp. 1245–1261, Mar. 2024, doi: 10.2166/wcc.2024.559.
- [13] I. Maulita and A. M. Wahid, “Prediksi Magnitudo Gempa Menggunakan Random Forest, Support Vector Regression, XGBoost, LightGBM, dan Multi-Layer Perceptron Berdasarkan Data Kedalaman dan Geolokasi,” *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 4, no. 5, pp. 221–232, Dec. 2024, doi: 10.52436/1.jpti.470.
- [14] S. Rahmadani, C. S. Rahayu, A. Salim, and K. N. Cahyo, “Deteksi Emosi Berdasarkan Wicara Menggunakan Deep Learning Model,” *Jurnal Informatika Teknologi dan Sains (Jinteks)*, vol. 4, no. 3, pp. 220–224, 2022, doi: 10.51401/jinteks.v4i3.1952.
- [15] A. Younesi, M. Ansari, M. Fazli, A. Ejlali, M. Shafique, and J. Henkel, “A Comprehensive Survey of Convolutions in Deep Learning: Applications, Challenges, and Future Trends,” Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.15490>
- [16] Moch Arif Ramhatullah, “95563-299867-1-PB,” 2025.
- [17] arahmah, “arahmah,+08-1224-Deteksi+Citra+Daun+untuk+Klasifikasi+Penyakit+Padi+menggunakan+Pendekatan+Deep+Learning+dengan+Model+CNN,” 2024.
- [18] E. da S. Farias and E. P. Junior, “Application of Attention Mechanism with Bidirectional Long Short-Term Memory (BiLSTM) and CNN for Human Conflict Detection using Computer Vision,” Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2502.18555>
- [19] S. Kasus, S. Meteorologi Citeko, K. Bogor, J. Barat Sofia Octaviana, Y. Mentari Indah, and I. Pertanian Bogor, “Perbandingan Metode LSTM dan BiLSTM untuk Prediksi Data Curah Hujan,” *BIAStatistics: Journal Of Statistics Theory and Applications*, pp. 45–52, 2025, [Online]. Available: <https://biostatistics.statistics.unpad.ac.id/?journal=biostatistics>
- [20] F. Abdillah, A. I. Hadiana, and M. Melina, “Prediksi Curah Hujan Menggunakan Metode Bi-LSTM dan GRU Berbasis Data Iklim,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 12–21, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2305.