

PENERAPAN DEEP LEARNING UNTUK DETEKSI BANJIR BERBASIS CITRA SATELIT DI INDONESIA

Yusdi Nugraha¹, Bambang Irawan²

Universitas Muhadi Setiabudi Brebes

E-mail: nugrahayusdi903@gmail.com¹, bambangumus@gmail.com²

Abstrak

Banjir merupakan salah satu bencana hidrometeorologi yang sering terjadi di Indonesia dan menimbulkan dampak signifikan terhadap kehidupan masyarakat, infrastruktur, serta perekonomian. Upaya mitigasi dan penanganan banjir memerlukan sistem deteksi yang cepat dan akurat agar kerugian dapat diminimalkan. Perkembangan teknologi penginderaan jauh dan deep learning membuka peluang besar dalam pengembangan sistem deteksi banjir berbasis data. Penelitian ini bertujuan untuk mengembangkan model deteksi banjir menggunakan metode Convolutional Neural Network (CNN) berbasis data citra satelit dan parameter cuaca yang direpresentasikan dalam bentuk dataset numerik. Data yang digunakan merupakan dataset berformat CSV dengan jumlah 5.000 data, yang merepresentasikan kondisi banjir dan tidak banjir. Dataset dibagi menjadi data pelatihan dan data pengujian untuk membangun serta mengevaluasi kinerja model. Model CNN dibangun menggunakan beberapa lapisan convolution, pooling, dan fully connected layer, serta dilakukan proses pelatihan (training) dan evaluasi menggunakan confusion matrix. Hasil penelitian menunjukkan bahwa model CNN yang diusulkan mampu mencapai tingkat akurasi sebesar 98%. Selain itu, nilai precision, recall, dan F1-score yang tinggi pada kedua kelas menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode CNN efektif digunakan untuk deteksi banjir berbasis data citra satelit dan cuaca. Model yang dihasilkan berpotensi untuk dikembangkan lebih lanjut sebagai bagian dari sistem peringatan dini banjir guna mendukung pengambilan keputusan dalam mitigasi bencana di Indonesia.

Kata Kunci — Banjir, Deep Learning, Convolutional Neural Network, Citra Satelit, Deteksi Banjir.

1. PENDAHULUAN

Banjir merupakan bencana alam yang terus menerus mengancam pemukiman manusia, pertanian, dan infrastruktur di seluruh Indonesia. Banjir adalah fenomena alam di mana wilayah dataran banjir tidak mampu menyerap jumlah air yang berlebih akibat luapan sungai atau curah hujan yang tinggi, sehingga terjadi genangan di permukaan. Banjir menjadi ancaman serius ketika daerah yang telah dikembangkan menjadi kawasan pemukiman, pertanian, perkebunan, dan tempat aktivitas manusia lainnya terendam, menyebabkan kerugian baik dalam hal korban jiwa maupun kerugian material. (Dhanisa et al., 2024)

Tingkat risiko banjir yang tinggi di berbagai wilayah Indonesia juga dipengaruhi oleh faktor geografis, curah hujan yang ekstrem, serta perubahan tata guna lahan. (IRBI, 2022) dalam Indeks Risiko Bencana Indonesia menegaskan bahwa sebagian besar wilayah perkotaan dan daerah aliran sungai memiliki tingkat kerentanan banjir yang tinggi, sehingga diperlukan sistem pemantauan yang cepat dan akurat.

Convolutional Neural Network (CNN) merupakan salah satu arsitektur deep learning yang sangat efektif dalam pengolahan data citra karena mampu mengekstraksi fitur spasial secara otomatis. Penelitian terbaru menunjukkan bahwa CNN mampu meningkatkan akurasi deteksi banjir secara signifikan dibandingkan metode machine learning tradisional. (Tavus et al., 2022)

Dengan mempertimbangkan keunggulan CNN dan ketersediaan data satelit, penelitian ini mengkaji penerapan CNN untuk deteksi banjir berbasis data citra yang direpresentasikan dalam bentuk dataset terstruktur. Pendekatan ini diharapkan mampu memberikan hasil klasifikasi yang akurat dan dapat digunakan sebagai dasar pengambilan keputusan dalam mitigasi bencana. (Bathe, 2024)

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menerapkan metode CNN dalam mendeteksi banjir berbasis data citra dan data pendukung cuaca yang direpresentasikan dalam bentuk dataset terstruktur. Diharapkan hasil penelitian ini dapat menjadi kontribusi dalam

pengembangan sistem mitigasi bencana banjir berbasis teknologi cerdas.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen, yaitu membangun dan mengevaluasi model Convolutional Neural Network (CNN) untuk mendeteksi kejadian banjir berdasarkan data citra yang telah diekstraksi menjadi fitur numerik. Pendekatan eksperimental dipilih karena memungkinkan evaluasi performa model secara objektif menggunakan metrik evaluasi tertentu.(Stateczny et al., 2023)

Dataset yang digunakan dalam penelitian ini berbentuk file CSV yang berisi data hasil ekstraksi citra satelit, meliputi parameter spektral, tekstur, serta indikator lingkungan terkait kondisi banjir. Dataset terdiri dari 5.000 data dengan dua kelas, yaitu banjir dan tidak banjir, sehingga cukup representatif untuk proses pelatihan model CNN.(Wu et al., 2023)

Tahapan pra-pemrosesan meliputi pembersihan data, normalisasi nilai fitur, serta pembagian data menjadi data latih dan data uji. Normalisasi dilakukan untuk memastikan seluruh fitur berada dalam skala yang sama sehingga mempercepat proses konvergensi model CNN.(Ghosh et al., 2022)

Convolutional Neural Network (CNN) merupakan urutan lapisan, kemudian setiap lapisan dari CNN menjadikan satu volume aktivasi ke yang lain melalui fungsi yang dapat dibedakan. CNN terdiri dari tiga lapisan hidden-layer utama: convolution layer, pooling layer, fully-connected layer; yang neuronnya tersusun dalam 3 dimensi (lebar, tinggi, kedalaman).CNN menjadi populer dan sering digunakan karena kinerjanya yang luar biasa dalam memecahkan berbagai masalah. Facebook adalah salah satu contohnya, yang perusahaannya menerapkan CNN untuk deteksi wajah yang ditandai. Google juga menggunakan CNN untuk pencarian fotodan pengenalan suara. Selain itu, pengaplikasian CNN di Spotify dan LINE Company banyak direkomendasikan pada sebagian besar proyek mereka.CNN awalnya dipelajari untuk karakter tulisan tangan dari kode pos. (Hidayat et al., 2022)

3. HASIL DAN PEMBAHASAN

Arsitektur Model CNN

Model Convolutional Neural Network (CNN) yang digunakan pada penelitian ini terdiri dari dua lapisan konvolusi (Conv1D), dua lapisan max pooling, satu lapisan flatten, satu lapisan dense, satu lapisan dropout, dan satu lapisan output. Arsitektur ini dirancang untuk mengolah data numerik hasil ekstraksi citra satelit dan variabel cuaca dalam bentuk deret fitur satu dimensi.

Model Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri dari dua lapisan convolutional, dua lapisan max pooling, serta lapisan fully connected. Arsitektur model CNN secara lengkap ditunjukkan pada Gambar 3.1.

Layer (type)	Output Shape	Param #
conv1d_4 (Conv1D)	(None, 6, 32)	96
max_pooling1d_4 (MaxPooling1D)	(None, 3, 32)	0
conv1d_5 (Conv1D)	(None, 2, 64)	4,160
max_pooling1d_5 (MaxPooling1D)	(None, 1, 64)	0
flatten_2 (Flatten)	(None, 64)	0
dense_4 (Dense)	(None, 64)	4,160
dropout_2 (Dropout)	(None, 64)	0
dense_5 (Dense)	(None, 1)	65

Total params: 8,481 (33.13 KB)
 Trainable params: 8,481 (33.13 KB)
 Non-trainable params: 0 (0.00 B)


Gambar 1 Arsitektur Model CNN untuk Deteksi Banjir

Berdasarkan ringkasan model (model summary), total parameter yang digunakan sebanyak 8.481 parameter, seluruhnya bersifat trainable. Jumlah parameter yang relatif kecil ini menunjukkan bahwa model cukup ringan dan efisien, sehingga sesuai untuk diterapkan pada sistem deteksi banjir dengan kebutuhan komputasi yang tidak terlalu besar.

Proses Pelatihan Model

Proses pelatihan model dilakukan menggunakan dataset sebanyak 5.000 data, yang dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Proses training dilakukan selama 30 epoch dengan optimizer Adam dan fungsi loss binary cross-entropy.

Berdasarkan grafik akurasi, terlihat bahwa nilai akurasi data latih dan data validasi mengalami peningkatan yang stabil seiring bertambahnya epoch. Akurasi pelatihan mencapai nilai mendekati 99%, sedangkan akurasi validasi berada pada kisaran 95–98%. Hal ini menunjukkan bahwa model mampu mempelajari pola data dengan baik tanpa mengalami overfitting yang signifikan.




Gambar 2 Grafik Akurasi Training dan Validasi

Analisis Loss

Grafik loss menunjukkan tren penurunan baik pada data latih maupun data validasi. Nilai loss data latih menurun secara konsisten hingga di bawah 0,05, sementara loss validasi berada pada kisaran 0,06–0,10. Pola ini menunjukkan bahwa proses optimasi berjalan dengan baik dan model mampu meminimalkan kesalahan prediksi selama pelatihan.


Perbedaan kecil antara loss data latih dan data validasi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.



Gambar 3 Grafik loss Training dan validasi

Grafik loss pada Gambar 3 menunjukkan bahwa nilai loss mengalami penurunan yang konsisten seiring bertambahnya epoch, yang menandakan model berhasil mempelajari pola data dengan baik tanpa overfitting yang signifikan

Evaluasi Model Menggunakan Confusion Matrix



Berdasarkan confusion matrix pada Gambar 4, model CNN mampu mengklasifikasikan data dengan sangat baik, ditunjukkan oleh jumlah True Negative dan True Positive yang dominan.

Evaluasi performa model dilakukan menggunakan confusion matrix untuk mengetahui kemampuan model dalam mengklasifikasikan kondisi banjir dan tidak banjir. Berdasarkan confusion matrix, diperoleh nilai True Negative (TN) sebesar 896, False Positive (FP) sebesar 7, False Negative (FN) sebesar 9, dan True Positive (TP) sebesar 88.

Hasil tersebut menunjukkan bahwa model sangat baik dalam mengklasifikasikan kelas tidak banjir, dengan tingkat kesalahan yang sangat rendah. Pada kelas banjir, model juga mampu mendeteksi sebagian besar kejadian banjir dengan baik meskipun masih terdapat sedikit kesalahan prediksi.

Akurasi, Presisi, Recall, dan F1-Score

Berdasarkan classification report, model menghasilkan akurasi keseluruhan sebesar 98%. Untuk kelas tidak banjir, diperoleh nilai presisi, recall, dan F1-score masing-masing sebesar 0,99. Sementara itu, untuk kelas banjir, model menghasilkan presisi sebesar 0,93, recall sebesar 0,91, dan F1-score sebesar 0,92.

Tabel 1 Hasil Evaluasi Model CNN

	precision	recall	f1-score	support
0	0.99	0.99	0.99	903
1	0.93	0.91	0.92	97
accuracy			0.98	1000
macro avg	0.96	0.95	0.95	1000
weighted avg	0.98	0.98	0.98	1000

Nilai metrik evaluasi tersebut menunjukkan bahwa model CNN yang dibangun memiliki kinerja yang sangat baik dan layak digunakan sebagai sistem pendukung deteksi banjir berbasis data citra satelit dan cuaca.

Pembahasan Hasil

Hasil penelitian ini menunjukkan bahwa penerapan metode deep learning dengan arsitektur CNN mampu memberikan performa yang tinggi dalam mendeteksi banjir. Integrasi data numerik hasil pengolahan citra satelit dan variabel cuaca terbukti efektif dalam meningkatkan akurasi klasifikasi.

Dengan akurasi di atas 80% dan bahkan mencapai 98%, model yang diusulkan berpotensi untuk dikembangkan lebih lanjut sebagai bagian dari sistem peringatan dini banjir. Ke depannya, performa model masih dapat ditingkatkan dengan penambahan data riil, optimasi arsitektur CNN, serta integrasi data spasial secara langsung dari citra satelit resolusi tinggi.

3. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai deteksi banjir berbasis deep learning menggunakan metode Convolutional Neural Network (CNN), dapat disimpulkan bahwa pendekatan CNN mampu memberikan kinerja yang sangat baik dalam mengklasifikasikan kondisi banjir dan tidak banjir. Model CNN yang dibangun menggunakan data numerik hasil ekstraksi citra satelit dan parameter cuaca berhasil mempelajari pola-pola yang relevan untuk mendukung proses deteksi banjir secara otomatis.

Hasil pelatihan model menunjukkan bahwa CNN mencapai tingkat akurasi sebesar 98%, yang mengindikasikan bahwa model memiliki kemampuan prediksi yang sangat tinggi. Selain itu, nilai precision, recall, dan F1-score yang tinggi pada kedua kelas menunjukkan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga konsisten dalam mengidentifikasi kejadian banjir maupun kondisi tidak banjir.

Berdasarkan hasil evaluasi menggunakan confusion matrix, model CNN mampu meminimalkan kesalahan klasifikasi, baik false positive maupun false negative. Hal ini menunjukkan bahwa model memiliki tingkat keandalan yang baik dan dapat digunakan sebagai dasar dalam sistem pendukung pengambilan keputusan terkait mitigasi dan peringatan dini banjir.

Dengan demikian, penelitian ini membuktikan bahwa penerapan metode CNN pada data berbasis citra satelit dan cuaca dapat menjadi solusi yang efektif dalam deteksi banjir. Pendekatan ini berpotensi untuk dikembangkan lebih lanjut sebagai bagian dari sistem peringatan dini bencana banjir di Indonesia.

DAFTAR PUSTAKA

- Bathe, K. (2024). DSAAM-UNet: Flood Detection Based on Lightweight Deep Learning Model and Satellite Imagery. *International Journal of Intelligent Systems and Applications in Engineering*, 12(4), 2554–2563. <https://ijisae.org/index.php/IJISAE/article/view/6682>
- Dhanisa, R., Sampurno, J., & Perdhana, R. (2024). Aplikasi Citra Sentinel-1 SAR untuk Deteksi Banjir di Kecamatan Sandai, Kabupaten Ketapang, Kalimantan Barat. *Jurnal Ilmu Lingkungan*, 22(3), 672–677. <https://doi.org/10.14710/jil.22.3.672-677>
- Ghosh, B., Garg, S., & Motagh, M. (2022). Automatic flood detection from sentinel-1 data using deep learning architectures. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 5(3), 201–208. <https://doi.org/10.5194/isprs-Annals-V-3-2022-201-2022>
- Hidayat, M. A., Husni, N. L., & Damsi, F. (2022). Pendeteksi Banjir Dengan Image Processing Berbasis Convolutional Neural Network (CNN) pada Kamera Pengawas. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 2(2), 10–18. <https://doi.org/10.57152/malcom.v2i2.382>
- IRBI. (2022). Indeks Risiko Bencana Indonesia Tahun 2021. Pusat Data, Informasi Dan Komunikasi Kebencanaan BNPB, 16.
- Stateczny, A., Praveena, H. D., Krishnappa, R. H., Chythanya, K. R., & Babysarojam, B. B. (2023). Optimized Deep Learning Model for Flood Detection Using Satellite Images. *Remote Sensing*, 15(20). <https://doi.org/10.3390/rs15205037>
- Tavus, B., Can, R., & Kocaman, S. (2022). A Cnn-based flood mapping approach using sentinel-1 data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 5(3), 549–556. <https://doi.org/10.5194/isprs-Annals-V-3-2022-549-2022>
- Wu, X., Zhang, Z., Xiong, S., Zhang, W., Tang, J., Li, Z., An, B., & Li, R. (2023). A Near-Real-Time Flood Detection Method Based on Deep Learning and SAR Images. *Remote Sensing*, 15(8). <https://doi.org/10.3390/rs15082046>.