

BINATRA: Sistem Informasi Terintegrasi Berbasis IoT dan LSTM untuk Mitigasi Banjir

Zahwa Farah Albani
Direktorat Kampus Surabaya
Telkom University

Surabaya, Indonesia
albani@student.telkomuniversity.ac.id

Muhammad Adib Kamali, S.T., M.Eng.
Direktorat Kampus Surabaya
Telkom University
Surabaya, Indonesia
adibmkamali@telkomuniversity.ac.id

M. Nizar Palefi Ma'ady, S.Kom.,
M.Kom., M.IM.
Direktorat Kampus Surabaya
Telkom University
Surabaya, Indonesia
mnizarpm@telkomuniversity.ac.id

Abstrak—Banjir merupakan bencana yang kerap melanda Kota Surabaya karena posisinya berada di hilir Sungai Brantas yang bermuara ke Selat Madura, sehingga masih terdapat sekitar 117 titik rawan banjir. Sistem pemantauan manual yang selama ini digunakan memiliki keterbatasan dalam kecepatan dan akurasi penyampaian informasi, sehingga dapat menghambat proses pengambilan keputusan. Penelitian ini bertujuan merancang dan mengembangkan sistem peringatan dini banjir berbasis Internet of Things (IoT) yang mampu memantau ketinggian muka air secara real-time serta memprediksi potensi banjir menggunakan algoritma Long Short-Term Memory (LSTM). Sistem yang dibangun memanfaatkan sensor ultrasonik untuk pengukuran ketinggian air dan Application Programming Interface (API) dari OpenWeather sebagai sumber data curah hujan. Data kemudian diintegrasikan pada platform perangkat lunak berupa website dashboard dan model prediksi LSTM. Pengujian dilakukan menggunakan data hasil pengambilan selama 20 hari, menghasilkan 1.794 sampel dengan interval 15 menit dan 2.784 sampel dengan interval 1 menit. Hasil evaluasi menunjukkan bahwa LSTM memiliki performa prediksi yang lebih baik untuk forecasting 1 jam kedepan terhadap interval 15 menit sesuai dengan standar hidrologi dibandingkan Convolutional Neural Network (CNN), dengan nilai RMSE masing-masing 9,389 dan 9,465. Analisis pada berbagai forecasting horizon juga menunjukkan bahwa LSTM tetap stabil dan akurat dalam memprediksi ketinggian muka air untuk jangka waktu 1 hingga 24 jam kedepan. Temuan ini membuktikan bahwa LSTM merupakan algoritma yang lebih unggul untuk diterapkan pada sistem peringatan dini banjir berbasis IoT di lingkungan urban.

Kata kunci—Banjir, FEWS, LSTM, IoT.

I. PENDAHULUAN

Dinas Sumber Daya Air dan Bina Marga (DSDABM) Kota Surabaya menjadikan pemeliharaan saluran primer dan sekunder, khususnya pemantauan ketinggian muka air sungai, sebagai prioritas utama dalam upaya pengendalian banjir, terutama pada musim hujan [1]. Secara geografis, Kota Surabaya memiliki risiko banjir yang cukup tinggi karena terletak pada wilayah Sistem Brantas Hilir yang bermuara ke Selat Madura. Berdasarkan kondisi tersebut, teridentifikasi sebanyak 117 titik rawan banjir di wilayah Kota Surabaya. Salah satu strategi mitigasi yang diterapkan adalah pemanfaatan sungai-sungai kecil sebagai *buffer* bagi sungai utama melalui pembangunan pintu air. Namun, strategi ini memiliki keterbatasan, terutama apabila kapasitas sungai kecil tidak memadai. Kondisi tersebut terjadi pada Sungai Ketintang Wiyata, yang berfungsi sebagai saluran pembuangan dari Sungai Rolag.

Kapasitas sungai yang terbatas menyebabkan sungai tidak mampu menampung limpasan air saat hujan dengan intensitas tinggi dan durasi lama, sehingga menimbulkan banjir lokal dengan frekuensi yang cukup tinggi. Meskipun DSDABM telah melakukan pemeliharaan secara rutin, sistem pemantauan yang masih bersifat manual mengakibatkan keterlambatan dalam deteksi dini potensi banjir. Padahal, beberapa kawasan padat penduduk di sekitar Sungai Surabaya memiliki riwayat genangan air yang tinggi, yang berpotensi menimbulkan kerugian material hingga korban jiwa [2].

Berdasarkan permasalahan tersebut, penerapan Flood Early Warning System (FEWS) berbasis Internet of Things (IoT) dengan metode Long Short-Term Memory (LSTM) dinilai sebagai solusi yang tepat untuk meningkatkan efektivitas mitigasi banjir.

Dibandingkan dengan metode Convolutional Neural Network (CNN) yang juga digunakan dalam proses *forecasting*, LSTM memiliki kemampuan yang lebih baik dalam menangkap ketergantungan data jangka panjang, dengan tingkat akurasi prediksi mencapai 63,6%, sedangkan CNN sebesar 62% [3].

Sistem FEWS ini didukung oleh perangkat sensor ultrasonik, data curah hujan berbasis Application Programming Interface (API), serta unit kendali berbasis internet yang mampu memantau kondisi sungai secara *real-time* dan mengirimkan data ke server pusat secara otomatis. Selain itu, teknologi Artificial Intelligence (AI) diimplementasikan untuk memprediksi potensi kenaikan muka air pada beberapa titik kritis di Kota Surabaya berdasarkan data historis dan data sensor terkini. Penelitian ini bertujuan untuk menghasilkan sistem peringatan dini banjir berbasis IoT yang mampu memantau ketinggian muka air dan intensitas curah hujan secara *real-time* dengan interval pengambilan data setiap 15 menit. Data yang diperoleh selanjutnya diproses menggunakan model prediksi LSTM untuk memperkirakan potensi terjadinya banjir dalam rentang waktu tertentu. Hasil prediksi dan pemantauan kemudian diintegrasikan ke dalam aplikasi berbasis website sehingga informasi peringatan dapat diakses dengan cepat oleh masyarakat dan pihak berwenang guna mendukung pengambilan keputusan yang tepat waktu.

II. KAJIAN TEORI

Penanggulangan banjir di Kota Surabaya dilakukan melalui berbagai kebijakan dan pembangunan infrastruktur, seperti pengelolaan sungai, pembangunan waduk, serta *long storage* untuk menahan debit air. Meskipun kewenangan telah didesentralisasikan, koordinasi antarinstansi masih menjadi tantangan. Di sisi lain, masyarakat turut berperan melalui pengajuan permohonan pembersihan sungai. Selain itu, akses terhadap keadilan dan partisipasi publik dalam pengambilan keputusan juga menjadi bagian penting dari strategi penanggulangan banjir [4].

Peningkatan kapasitas serta pengawasan pembangunan di wilayah rawan banjir diperlukan untuk menekan risiko. Namun, pembuangan air ke waduk atau sungai kecil memiliki potensi dampak negatif, seperti meningkatnya risiko banjir apabila volume air melebihi kapasitas tampung, serta pencemaran lingkungan akibat

limbah yang tidak terkelola dengan baik. Pembuangan yang tidak terkontrol juga dapat menyebabkan pendangkalan waduk dan sungai, mengurangi daya tampung, serta mengganggu keseimbangan ekosistem di sekitarnya [5].

Beberapa penelitian telah mengembangkan sistem yang berpotensi signifikan dalam melindungi korban, properti, serta memitigasi kerusakan akibat banjir. Salah satunya menggunakan kalibrasi pelampung yang terpasang pada potensiometer sehingga memungkinkan pengukuran ketinggian air secara presisi. Namun, data cuaca yang diperoleh hanya mencakup wilayah geografis tertentu, sehingga cakupan informasinya masih terbatas [6]. Sistem ini dapat diperbarui dengan memanfaatkan API cuaca untuk memperoleh data curah hujan secara *real-time* serta menambahkan sensor ultrasonik untuk mengukur tinggi muka air sungai, sehingga akurasi prediksi pada sistem FEWS dapat ditingkatkan [7].

Penelitian lain memanfaatkan kecerdasan buatan Artificial Neural Network (ANN) dengan komputasi yang relatif ringan sehingga lebih efisien dalam implementasi. Model ini mampu memprediksi banjir secara *real-time* dengan tingkat akurasi 94,2%, lebih tinggi dibandingkan metode lain seperti Logistic Regression dan Random Forest. Dataset yang digunakan mencakup parameter badan air seperti kelembapan, suhu, curah hujan, aliran air, dan elevasi. Namun, ANN kurang efektif dalam menangkap pola temporal jangka panjang, sehingga akurasi menurun signifikan ketika prediksi dilakukan lebih dari dua jam tanpa optimasi arsitektur [8]. Oleh karena itu, penggunaan LSTM sebagai pembaruan model prediksi dapat meningkatkan akurasi hingga horizon 72 jam karena LSTM mampu mengelola dependensi temporal jangka panjang secara optimal [9].

Penerapan LSTM juga diteliti dalam karya yang menunjukkan bahwa mekanisme *multi-head attention* memberikan kemampuan adaptif dan optimal pada model LSTM sehingga proses pembelajaran menjadi lebih cepat. Namun, data yang digunakan masih bersifat statis dan belum mendukung prediksi *real-time*. Oleh karena itu, penambahan data dinamis seperti curah hujan diperlukan agar sistem mampu menghasilkan prediksi secara *real-time* [10].

Prediksi banjir berbasis LSTM juga dilakukan dengan mengombinasikan LSTM dan Random Forest dalam pendekatan *Hybrid Machine Learning*. Model ini mencapai akurasi 99% pada tahap pelatihan dan mampu memprediksi kejadian banjir dengan akurasi 63,6%. Data uji diperoleh dari laporan tahunan, bulanan, harian, dan musiman yang bersumber dari situs petabencana.id, yang mengumpulkan serta menyebarkan informasi bencana secara *real-time* [11].

Selain itu, sistem deteksi dini banjir berbasis perangkat keras FEWS menggunakan aplikasi Blynk juga telah dikembangkan. Sistem ini memanfaatkan sensor ketinggian air, sensor hujan, suhu, dan kelembapan yang dapat diakses secara *real-time* melalui aplikasi. Namun, sistem ini belum mampu memprediksi kejadian banjir, melainkan hanya memberikan peringatan ketika tinggi air sungai telah melewati batas sensor *water leveling* [12].

Berdasarkan tabel “Kekasaran Dinding Alur Sungai Berdasarkan Manning” yang dirilis oleh Standar Nasional Indonesia (SNI), tingkat kewaspadaan sungai dibedakan berdasarkan lebar muka air banjir menjadi dua kategori, yaitu Sungai Kecil (lebar muka air banjir < 30 m) dan Sungai Besar (lebar muka air banjir > 30 m) [13]. Berdasarkan klasifikasi tersebut, kemudian ditetapkan parameter ketinggian air sungai agar dapat diproses dan dibandingkan dengan data curah hujan yang diperoleh dari API cuaca. Proses ini dilakukan menggunakan metode LSTM untuk menghasilkan prediksi yang akurat dan bersifat *real-time*, yang selanjutnya diintegrasikan ke dalam sebuah website agar dapat diakses oleh masyarakat, khususnya warga Kentintang Wiyata.

Adapun parameter yang digunakan yaitu curah hujan (Tabel 1) yang digunakan dalam penelitian ini adalah milimeter (mm) karena merupakan standar internasional dalam bidang meteorologi, hidrologi, serta perencanaan teknik seperti

drainase, irigasi, dan bendungan. Satuan ini memiliki resolusi yang tinggi sehingga lebih sensitif terhadap perubahan kecil curah hujan dan lebih presisi untuk kebutuhan analisis serta prediksi pada sistem yang dikembangkan [14].

TABEL 1
(INTENSITAS CURAH HUJAN HARIAN INDONESIA)

Intensitas Curah Hujan Harian Indonesia	
Tidak Hujan	-
Ringan	0,5 – 20 mm/hari
Sedang	20 – 50 mm/hari
Lebat	50 – 100 mm/hari
Sangat Lebat	100 – 150 mm/hari
Ekstrem	> 150 mm/hari


TABEL 2
(PARAMETER KETINGGIAN AIR SUNGAI WIYATA)

Parameter Ketinggian Air	
Aman	<= 80 cm
Waspada	81 – 120 cm
Siaga	121 – 130 cm
Bahaya	131 cm

Sementara itu, ketinggian muka air sungai (Tabel 2) dinyatakan dalam satuan sentimeter (cm) karena rentang pengukurannya relatif kecil, sehingga penggunaan cm memberikan tingkat ketelitian yang lebih baik dibandingkan meter dalam sistem FEWS [2]. Pemilihan satuan ini mendukung akurasi pengolahan data sensor dalam memantau kondisi hidrologis secara detail.

Model Long Short-Term Memory (LSTM) dipilih karena kemampuannya dalam mengolah data deret waktu secara efektif, khususnya dalam menangani ketergantungan jangka panjang seperti pola curah hujan dan fluktuasi tinggi muka air sungai. Karakteristik tersebut menjadikan LSTM sangat sesuai untuk sistem peringatan dini banjir (FEWS) yang berbasis data IoT yang bersifat dinamis dan kontinu. Integrasi LSTM dengan sistem sensor dan antarmuka web memungkinkan proses prediksi dilakukan secara *real-time* dengan tingkat akurasi yang baik, sehingga dapat mempercepat pengambilan keputusan pada kondisi darurat, mengurangi potensi kerugian, serta mendukung perencanaan dan pengelolaan wilayah perkotaan yang lebih tangguh terhadap bencana banjir.


III. METODE



GAMBAR 1
(FLOWCHART ALUR PENELITIAN)

Gambar 1 menunjukkan alur penelitian yang menggunakan pendekatan *prototyping* dengan metode iteratif, di mana pengembangan sistem dilakukan secara


bertahap melalui proses perancangan, pengujian, dan evaluasi. Pendekatan ini dipilih agar sistem monitoring berbasis IoT dan model prediksi, LSTM yang dikembangkan dapat disempurnakan secara berkelanjutan hingga mencapai hasil yang optimal dan siap diimplementasikan. Penelitian diawali dengan studi literatur untuk memperoleh referensi terkait sistem IoT dan metode LSTM, kemudian dilanjutkan dengan identifikasi masalah yang berkaitan dengan pemantauan banjir. Tahap berikutnya adalah perancangan kebutuhan sistem yang mencakup analisis kebutuhan fungsional dan nonfungsional. Pada tahap ini ditentukan komponen utama yang dibutuhkan, seperti sensor jarak (HC-SR04), perangkat komunikasi IoT (ESP32), server, serta perangkat lunak untuk pengolahan data dan prediksi banjir. Setelah kebutuhan sistem ditetapkan, dilakukan pengumpulan dataset yang diperoleh dari hasil pengukuran lapangan serta pihak terkait, termasuk Bapak RW Ketintang Wiyata dan warga yang tinggal di sekitar bantaran sungai. Data tersebut digunakan sebagai dasar dalam pelatihan dan pengujian model LSTM. Selanjutnya dilakukan perancangan prototipe IoT, pelatihan model LSTM, dan pengembangan prototipe website secara paralel. Ketiga komponen ini diintegrasikan untuk membentuk sistem monitoring dan prediksi banjir yang utuh. Model LSTM dilatih menggunakan dataset yang telah dikumpulkan agar mampu menghasilkan prediksi ketinggian air secara akurat. Apabila hasil pengujian belum memenuhi kriteria yang ditetapkan, maka dilakukan perbaikan secara iteratif. Setelah sistem dinyatakan berhasil dan memenuhi tujuan penelitian, proses diakhiri dengan penarikan kesimpulan.



GAMBAR 2
(BLOK DIAGRAM SISTEM YANG DIBUAT)

Gambar 2 merupakan alur kerja sistem yang dibangun melalui siklus perancangan, implementasi, pengujian, dan evaluasi secara berulang hingga diperoleh performa yang optimal dan stabil. Sistem terdiri dari tiga komponen utama, yaitu perangkat IoT di lapangan, server backend sebagai pusat pemrosesan data, dan antarmuka web sebagai media visualisasi. Perangkat IoT menggunakan sensor ultrasonik HC-SR04 untuk mengukur jarak antara sensor dan permukaan air sungai dalam satuan sentimeter. Sebelum pengambilan data dilakukan, sensor dikalibrasi dengan menentukan nilai *calibration*, yaitu jarak tetap dari dasar sungai ke posisi sensor yang diperoleh melalui pengukuran manual. Nilai ini bersifat konstan dan digunakan sebagai acuan untuk menghitung ketinggian air aktual (*depth*) menggunakan persamaan $depth = calibration - water\ level$. Data curah hujan diperoleh dari layanan OpenWeather melalui API sebagai variabel tambahan yang mendukung analisis kenaikan muka air. Seluruh data sensor dikirimkan


oleh mikrokontroler ESP32 ke server menggunakan protokol komunikasi MQTT dan disimpan dalam basis data MySQL yang berisi atribut seperti waktu pengukuran (*timestampt*), *water level*, *rainfall*, *calibration*, *depth*, status, dan identitas perangkat yang ditunjukkan *flowchart* pada Gambar 3.



GAMBAR 3
(FLOWCHART ALUR PENGOLAHAN DATA)

Data dikumpulkan dalam dua resolusi waktu, yaitu setiap 1 menit dan 15 menit selama periode 20 hari. Data dengan resolusi 1 menit diagregasi menjadi interval 15 menit untuk membentuk dataset deret waktu yang konsisten. Proses *preprocessing* dilakukan secara menyeluruh untuk memastikan kualitas data sebelum digunakan dalam pemodelan. Tahapan ini mencakup pembersihan data (*data cleaning*) untuk menangani nilai yang hilang (*missing value*), *noise*, dan *outlier* yang dapat disebabkan oleh gangguan sensor atau kondisi ekstrem. Nilai yang hilang diisi menggunakan interpolasi linear atau nilai rata-rata agar tidak mengganggu kontinuitas deret waktu. Selanjutnya dilakukan *clipping* agar seluruh nilai berada dalam batas fisik yang masuk akal, misalnya *rainfall* tidak bernilai negatif dan *water level* berada dalam rentang 0 hingga $calibration - 1$. Setelah itu dilakukan normalisasi agar seluruh fitur berada pada skala yang seragam sehingga mempercepat proses konvergensi model.

Selain pembersihan data, dilakukan pula *feature engineering* (Gambar 4) untuk meningkatkan kemampuan model dalam menangkap pola temporal. Fitur turunan yang dibentuk meliputi fitur waktu (jam dan hari dalam minggu) untuk menangkap pola musiman harian, akumulasi curah hujan dalam beberapa interval (15 menit, 1 jam, dan 3 jam), serta perubahan *water level* dalam beberapa langkah waktu sebagai indikator kecepatan kenaikan muka air. Target prediksi dibentuk dengan menggeser nilai *depth* satu langkah ke depan sehingga model memprediksi ketinggian air pada waktu berikutnya. Dataset akhir berbentuk deret waktu (*time-series*) dengan interval tetap 15 menit, bebas *missing value*, dan telah memiliki fitur numerik yang bersih serta representatif.



GAMBAR 4
(FLOWCHART ALUR PREPROCESSING DATA)

Data yang telah diproses kemudian dibentuk menjadi sekuens untuk model LSTM dengan panjang 96 langkah, yang merepresentasikan data satu hari penuh (96×15 menit = 24 jam). Dengan demikian, model memanfaatkan informasi historis selama 24 jam sebelumnya untuk memprediksi kondisi ketinggian air pada 1 hingga 24 jam ke depan. Model LSTM dilatih menggunakan data historis dan diimplementasikan pada server backend untuk menangani permintaan prediksi secara *real-time*. Setelah dilatih, model dikonversi ke format produksi dan diintegrasikan dengan sistem backend sehingga setiap data baru yang masuk dari IoT dapat langsung diproses dan menghasilkan nilai prediksi ketinggian air. Hasil prediksi kemudian disimpan kembali ke database dan ditampilkan melalui antarmuka web dalam bentuk informasi yang mudah dipahami oleh pengguna, meliputi ketinggian air aktual, curah hujan, serta status peringatan banjir (aman, waspada, siaga, bahaya).

Pengujian sistem dilakukan untuk mengevaluasi kinerja model dan keandalan sistem secara keseluruhan. Evaluasi dilakukan menggunakan dua dataset dengan resolusi waktu berbeda, yaitu dataset 1 menit dan dataset 15 menit. Kinerja model diukur menggunakan beberapa metrik evaluasi, yaitu Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), Nash–Sutcliffe Efficiency (NSE), Recall, Peak Error, dan Lead Time. Selain itu, dilakukan *ablation study* untuk menilai kontribusi fitur curah hujan terhadap performa model dengan membandingkan hasil prediksi model yang menggunakan fitur hujan dan yang tidak menggunakan fitur hujan.

IV. HASIL DAN PEMBAHASAN

A. Hasil Pengujian Model LSTM

Hasil pengujian pada Tabel 3 dan Tabel 4 menunjukkan bahwa pada kedua dataset, model *Long Short-Term Memory* (LSTM) secara konsisten menghasilkan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) yang lebih rendah dibandingkan model *Convolutional Neural Network* (CNN) pada seluruh horizon prediksi (1–24 jam).

TABEL 3
(PENGUJIAN AKURASI PREDIKSI DATASET 1 MENIT)

Horizon	Model	RMSE	MAPE	NSE	Recall (%)	PeakErr	LeadTime (h)
1h	LSTM	3.637	3.019	-0.790	0.00	2.531	0.000
1h	CNN	3.151	2.619	-0.343	0.00	2.035	0.000
3h	LSTM	3.456	3.691	-1.517	0.00	3.307	0.000
3h	CNN	5.104	5.499	-4.488	0.00	4.898	0.000


6h	LSTM	3.462	3.835	-1.899	0.00	3.557	0.000
6h	CNN	4.950	5.111	-4.929	0.00	4.619	0.000
12h	LSTM	3.880	3.638	-2.841	0.00	5.694	0.000
12h	CNN	4.316	4.276	-3.753	0.00	3.437	0.000
24h	LSTM	2.466	2.395	-0.551	0.00	5.770	0.000
24h	CNN	5.093	5.430	-5.615	0.00	5.964	0.000

TABEL 4
(PENGUJIAN AKURASI PREDIKSI DATASET 15 MENIT)

Horizon	Model	RMSE	MAPE	NSE	Recall (%)	PeakErr	LeadTime (h)
1h	LSTM	9.264	36.438	0.643	10.87	5.355	0.091
1h	CNN	10.137	63.418	0.572	0.00	6.554	0.000
3h	LSTM	10.739	83.217	0.522	1.09	9.191	0.000
3h	CNN	11.082	84.748	0.491	0.00	10.027	0.000
6h	LSTM	10.962	98.891	0.496	0.00	11.998	0.000
6h	CNN	10.855	91.823	0.506	0.00	11.938	0.000
12h	LSTM	12.742	175.843	0.289	0.00	15.924	0.000
12h	CNN	14.363	210.593	0.097	0.00	15.251	0.000
24h	LSTM	12.852	178.929	0.245	0.00	22.924	0.000
24h	CNN	14.121	228.385	0.089	0.00	21.629	0.000

Khusus pada dataset beresolusi 15 menit (Tabel 4) dengan horizon 24 jam, model LSTM mencatat nilai RMSE sebesar 12,85 cm, lebih baik dibandingkan CNN yang memperoleh 14,12 cm, sehingga memberikan peningkatan akurasi sebesar 9,2%. Nilai *Recall* dan *Lead Time* yang sama-sama bernilai 0 tidak menunjukkan kegagalan model, melainkan disebabkan oleh tidak adanya kejadian banjir kritis (kedalaman ≥ 100 cm) pada periode pengujian. Dengan demikian, model tidak memiliki titik acuan untuk mendeteksi puncak banjir secara statistik. Kondisi ini mencerminkan karakteristik dataset pengujian yang hanya memuat kejadian banjir berskala kecil.

B. Hasil Perangkat Keras



GAMBAR 5
(RANCANGAN ALAT FEWS)

Sistem IoT yang ditunjukkan pada Gambar 5 ini memanfaatkan energi surya yang diperoleh dari panel surya untuk mengisi baterai aki. Seluruh perangkat, termasuk tombol *power*, ditempatkan dalam box panel. Pengambilan data dilakukan menggunakan sensor HC. Selain itu, perangkat-perangkat yang terhubung ditempatkan di dalam boks panel. Di dalamnya terdapat LCD yang berfungsi menampilkan status baterai dari sistem tenaga surya (Gambar 6(a)) serta LCD lain yang menampilkan informasi kalibrasi pada perangkat FEWS (Gambar 6(b)). Pada *controller* sistem solar panel juga tersedia *port* USB yang saat ini dimanfaatkan untuk memasang modem sebagai sumber konektivitas internet. Dengan demikian, perangkat dapat mengirimkan data ke *website* secara otomatis sesuai interval yang telah ditetapkan, yaitu setiap 15 menit.



GAMBAR 6
(PERANGKAT IOT)

Lokasi instalasi perangkat dilakukan pada Sungai Ketintang Wiyata di dua titik yang berbeda. Perangkat pertama dipasang di area dekat pintu air, tepatnya pada titik ujung kiri atas pada Gambar (Gambar 6) dan difungsikan sebagai unit pengambil data pengujian. Sementara itu, perangkat kedua ditempatkan pada alur sungai yang sama, berada pada titik kanan bawah pada GambarGambar 6).



GAMBAR 7
(TITIK LOKASI PENEMPATAN ALAT)

Penetapan kedua lokasi ini didasarkan pada informasi yang diperoleh melalui wawancara dengan warga sekitar, yang mengungkapkan bahwa segmen sungai tersebut kerap mengalami genangan, khususnya saat terjadi hujan atau ketika aliran dari sungai utama dialirkan ke sungai berukuran lebih kecil. Kondisi tersebut menimbulkan potensi kerugian bagi masyarakat, baik bagi penduduk yang bermukim di sekitar bantaran sungai maupun bagi para pedagang yang beraktivitas di kawasan tersebut. Mempertimbangkan tingkat urgensi dan kebutuhan masyarakat terhadap upaya mitigasi, keberadaan perangkat ini diharapkan mampu menyediakan informasi ketinggian air secara *real-time* setiap 15 menit sehingga dapat mendukung sistem peringatan dini banjir serta meminimalkan dampak yang ditimbulkan.



GAMBAR 8
(PERBANDINGAN HASIL KALIBRASI DENGAN MANUAL - MEMBANDINGKAN AKURASI DATA)

Hasil perbandingan antara data kalibrasi dan pengukuran manual menunjukkan bahwa nilai hasil kalibrasi cenderung lebih tinggi dibandingkan pengukuran manual Gambar 8, dengan selisih sekitar 5.6 cm. Ketidaksesuaian ini muncul karena sensor HC memiliki kecenderungan menghasilkan pembacaan yang tidak stabil, terutama ketika dipengaruhi oleh kondisi lingkungan seperti turbulensi air, sudut pantul gelombang ultrasonik, serta variasi permukaan air yang tidak rata.

C. Hasil Perangkat Lunak



GAMBAR 9
(DASHBOARD ALAT)

Gambar 9 menampilkan *dashboard* status alat yang telah terpasang, terdapat kode alat, status koneksi, lokasi pemasangan, update atau instalasi terakhir, dan bagian pengeditan informasi terkait alat.




GAMBAR 10
(DASHBOARD UTAMA)

Gambar 10(a) menampilkan antarmuka *dashboard* dari perangkat *dedicated* 1 yang berfungsi untuk melakukan pengambilan dan pengumpulan data pelatihan sebagai dasar pembentukan model prediksi. Melalui tampilan ini, pengguna

dapat memantau kondisi sensor serta memastikan bahwa data yang direkam sesuai dengan kebutuhan proses *training*. Sementara itu, Gambar 10(b) memperlihatkan grafik keluaran dari perangkat *dedicated 2* yang digunakan khusus pada tahap pengujian. Grafik tersebut membantu pengguna dalam mengevaluasi akurasi, kestabilan, dan performa model ketika diterapkan pada data baru maupun pada kondisi operasional yang berbeda.

D. Hasil Pengujian Dengan Fitur Hujan



GAMBAR 11
(GRAFIK RMSE FITUR RAINFALL TERHADAP MODEL LSTM)

Berdasarkan visualisasi pada Gambar 11, Penambahan fitur *rainfall* memberikan peningkatan akurasi pada horizon prediksi jangka pendek (1–3 jam). Namun, pada horizon prediksi jangka menengah (6–12 jam), kinerja model yang menggunakan fitur *rainfall* mengalami penurunan dibandingkan dengan model tanpa fitur *rainfall*.

TABEL 5
(HASIL ABLATION STUDY — DENGAN RAINFALL VS TANPA RAINFALL)

Horizon	RMSE _w	MAPE _w	NSE _w	RMSE _{wo}	MAPE _{wo}	NSE _{wo}
1h	9.288	42.00	0.641	9.285	42.57	0.641
3h	9.830	67.00	0.600	10.309	75.73	0.560
6h	11.945	120.15	0.402	10.990	91.87	0.494
12h	12.873	179.31	0.274	12.184	138.89	0.350
24h	14.064	234.30	0.096	14.216	234.10	0.077

Pada Tabel 5 menunjukkan detail pada horizon pendek seperti 1 jam dan 3 jam, penambahan variabel curah hujan memberikan efek yang cenderung netral hingga sedikit meningkatkan performa model. Namun, pada horizon menengah seperti 6 jam dan 12 jam, penggunaan fitur hujan justru berasosiasi dengan penurunan akurasi pada beberapa indikator, seperti meningkatnya RMSE, menurunnya NSE, serta naiknya nilai MAPE. Hal ini dapat disebabkan oleh beberapa faktor, antara lain kualitas atau ketepatan representasi data hujan yang kurang memadai (misalnya noise atau resolusi temporal/spasial yang tidak cocok), pola hubungan nonlinier yang tidak berhasil dipelajari oleh model, maupun potensi overfitting akibat penambahan fitur tersebut. Meskipun demikian, karena dampaknya pada horizon 1 jam relatif netral hingga positif serta biaya komputasi dan implementasi yang rendah, memasukkan fitur curah hujan tetap menjadi pilihan yang menguntungkan untuk kebutuhan operasional.

V. KESIMPULAN

Berdasarkan hasil penelitian, sistem FEWS berbasis IoT dan LSTM yang dikembangkan mampu melakukan

pemantauan tinggi muka air sungai secara real-time dengan interval 15 menit serta memberikan peringatan dini hingga 1 jam ke depan, dengan performa terbaik pada horizon 1 jam menggunakan dataset resolusi 15 menit sebanyak 1.794 sampel. Untuk data beresolusi tinggi (1 menit), arsitektur CNN menunjukkan kinerja lebih baik karena mampu menangkap pola temporal lokal dan meredam fluktuasi jangka pendek. Penambahan fitur *rainfall* meningkatkan akurasi pada horizon pendek (1–3 jam), namun kurang efektif pada horizon menengah (6–12 jam), yang mengindikasikan perlunya pemodelan hidrologis yang lebih komprehensif. Secara keseluruhan, sistem telah memenuhi tujuan utama sebagai alat monitoring berkala dan peringatan dini banjir satu jam ke depan, meskipun pengembangan lanjutan masih diperlukan melalui perluasan dataset, variasi kondisi hidrometeorologi, serta analisis sensitivitas dan feature importance agar model sekuensial seperti LSTM dapat lebih stabil dan memiliki kemampuan generalisasi yang lebih baik dalam mendukung pengambilan keputusan pengelolaan risiko banjir.

REFERENSI

- [1] Dinas Sumber Daya Air dan Bina Marga Kota Surabaya, Laporan Kinerja Tahunan 2024: Pemeliharaan dan Pengawasan Saluran Drainase Kota Surabaya, Surabaya, 2024. [Online]. Available: <https://sda.surabaya.go.id>
- [2] Pemerintah Kota Surabaya, “Peta zonasi rawan genangan dan drainase Kota Surabaya,” 2023. [Online]. Available: <https://surabaya.go.id/peta-genangan>
- [3] A. Wijayanto, A. Sugiharto, and R. Santoso, “Identifikasi dini curah hujan berpotensi banjir menggunakan algoritma LSTM dan isolation forest,” Jurnal Teknologi Informasi dan Ilmu Komputer, vol. 11, pp. 637–646, Jul. 2024, doi: 10.25126/jtiik.938718.
- [4] R. I. Buchori, R. Rudiana, and Y. Nuryanto, “Good environmental governance dalam penanggulangan banjir di Kota Surabaya tahun 2024,” Jurnal Ilmu Sosial dan Ilmu Politik (JISIP), vol. 14, no. 3, pp. 542–564, 2025, doi: 10.33366/jisip.v14i3.3630.
- [5] M. A. Kamali and M. N. P. Ma’ady, “IoT-based flood disaster early detection system using hybrid fuzzy logic and neural networks,” TELKOMNIKA, vol. 22, pp. 976–984, Aug. 2024, doi: 10.12928/TELKOMNIKA.v22i4.25868.
- [6] Badan Meteorologi dan Geofisika, Peraturan Kepala BMG: Tata Cara Tetap Pelaksanaan Pengamatan dan Pelaporan Data Iklim dan Agroklimat, Jakarta: BMG, 2006.
- [7] S. N. Arinze et al., “Real-time IoT-enabled flood risk prediction and adaptive water redistribution with machine learning: A case study of Nigeria,” Modelling and Simulation in Engineering, vol. 2025, 2025, doi: 10.1155/mse/4694316.
- [8] M. Wajid et al., “Flood prediction system using IoT artificial neural network,” VFAST Transactions on Software Engineering, vol. 12, pp. 210–224, Mar. 2024, doi: 10.21015/vtse.v12i1.1603.
- [9] A. R. A. Alkharabsheh and L. M. Momani, “AI-driven flood prediction, monitoring, and warning systems: Design, evaluation, and simulation,” Iraqi Journal for Computer Science and Mathematics, vol. 6, Dec. 2025, doi: 10.52866/2788-7421.1337.

- [10] H. R. C. Arante et al., "Development of a secured IoT-based flood monitoring and forecasting system using genetic-algorithm-based neuro-fuzzy network," *Sensors*, vol. 25, Jul. 2025, doi: 10.3390/s25133885.
- [11] Z. Jailani and N. D. Jailani, "Hybrid machine learning prediksi banjir menggunakan LSTM dan random forests pada geodata," *INTECOMS: Journal of Information Technology and Computer Science*, vol. 8, 2025.
- [12] H. N. P. Wisudawan, *Design and Implementation of Real-Time Flood Early Warning System*, Tech. Rep., Universitas Islam Indonesia, 2021.
- [13] R. Byali et al., "IoT based early flood detection using machine learning," *International Journal of Research Publication and Reviews*, pp. 3780–3783, Jul. 2022, doi: 10.55248/gengpi.2022.3.7.30.
- [14] Adinugroho, "Perbandingan rasio split data training dan data testing menggunakan metode LSTM dalam memprediksi harga indeks saham Asia," Tech. Rep., Universitas Islam Negeri Syarif Hidayatullah Jakarta, Oct. 2022.

