

BAB 2

KAJIAN PUSTAKA


Bab ini menguraikan beberapa bagian utama. Bagian pertama adalah tinjauan pustaka yang merangkum penelitian terdahulu terkait prediksi banjir, mencakup pendekatan, data, hingga arah penelitian lanjutan. Bagian berikutnya adalah landasan teori yang menjelaskan konsep fundamental sebagai dasar penelitian ini, mulai dari definisi daerah pesisir, penambangan data, hingga metode spesifik.

2.1 Tinjauan Pustaka


Penelitian ini menempatkan banjir sebagai topik utama melalui berbagai pendekatan dalam kerangka penelitian yang digunakan Gambar 2.1. Pendekatan pertama yang berdasar pada aspek fisik menitikberatkan simulasi proses hidrologi dan hidrodinamika berdasarkan hukum fisika. Di dalamnya, terdapat metode fisik seperti pemodelan curah hujan-limpasan serta metode gabungan tingkat lanjut yang menyatukan model hidrologi dengan hidrodinamika. Hasil dari kedua pendekatan ini menghasilkan pemetaan banjir sebagai dasar untuk menganalisis dampak lebih lanjut, seperti luas genangan, korban jiwa, kerusakan harta benda dan prasarana, dampak ekonomi, serta aspek bahaya.

Sementara itu, pendekatan prediktif, yang berfokus pada pemanfaatan data historis untuk membangun model prediksi. Pendekatan ini mencakup analisis berbasis data melalui metode statistik maupun penambangan data, yang kemudian menghasilkan pemetaan banjir berupa luasan dan aspek bahaya.

Beberapa kajian lain, seperti analisis dampak sosial-ekonomi, perubahan iklim, pengembangan sistem peringatan dini, serta integrasi penginderaan jauh dengan data geospasial. Semua pendekatan ini saling melengkapi dalam upaya memahami dan mengelola potensi banjir secara komprehensif.



Gambar 2.1: Penelitian Terkait Prediksi Banjir dan Kerangka Konseptual



Gambar 2.2: Peta Bibliometrik Tren Penelitian Prediksi Banjir

Berdasarkan analisis peta bibliometrik pada Gambar 2.2, penelitian ini memetakan tren penelitian terkini sebagai *State of the Art (SOTA)* guna mengidentifikasi beberapa kesenjangan riset (*research gap*) utama yang menjadi landasan kebaruan penelitian ini:

1. Model Hibrida untuk Mengatasi Kelemahan Metode Tunggal: Analisis klaster *Hybrid Modeling (HBM)* menunjukkan hanya terdapat 23 artikel yang meninjau penggabungan dua metode atau lebih. Penelitian ini mengisi celah tersebut dengan mengintegrasikan Penghalusan Eksponensial Tripel (*Triple Exponential Smoothing, TES*) dan Jaringan Saraf Tiruan (*JST*) untuk menutupi kelemahan linearitas pada metode klasik.
2. Fokus pada Dinamika Pesisir (Banjir Rob): Meskipun klaster hidrologi masih didominasi oleh studi banjir sungai (31 artikel menyebutkan '*River*'), penelitian ini memberikan pembaruan dengan memfokuskan pada kawasan pesisir sebagai area yang jarang dikaji. Hal ini penting karena banjir pesisir memiliki dinamika yang lebih kompleks antara faktor darat (limpasan) dan laut (pasang surut).
3. Pembobotan Variabel secara Objektif dan *Data-Driven*: Memanfaatkan fondasi dari klaster dominan *Machine Learning* (68 artikel), penelitian ini menerapkan model JST secara *data-driven* untuk menghasilkan bobot bahaya banjir secara objektif. Pendekatan ini mereduksi subjektivitas dan bias manusia yang sering ditemukan pada metode konvensional seperti *Analytic Hierarchy Process (AHP)*.
4. Analisis Spasio-Temporal dengan Data Multivariat: Penelitian ini memanfaatkan variabel lingkungan (*Environmental Variables*) seperti curah hujan dan kenaikan air laut sebagai prediktor multivariat. Integrasi aspek temporal dari klaster *Time Series* (39 artikel) melalui TES dan aspek spasial melalui JST memungkinkan analisis yang lebih utuh dibandingkan

pendekatan univariat.

2.1.1 Lokasi Studi

Studi ini memfokuskan analisis prediksi bahaya banjir rob pada Kluster Pusat di Wilayah Pesisir Utara Jawa Tengah (Pantura) yang mencakup Kota Semarang, Kabupaten Demak, dan Kabupaten Jepara. Pemilihan lokasi ini sangat strategis karena koridor tersebut merupakan laboratorium alami untuk memodelkan interaksi ekstrem antara dinamika laut, kondisi geologis, dan tekanan aktivitas manusia (Marfai and King, 2008a; Marfai et al., 2014; Abidin et al., 2011; Susanto et al., 2021).

Justifikasi pemilihan kluster didasarkan pada dua argumen utama. Pertama, dari aspek keterpaparan urban dan geologis, ketiga daerah ini berada dalam zona pengaruh aktivitas urban padat di Semarang. Tekanan pembangunan dan perubahan tata guna lahan berkontribusi terhadap meningkatnya kerentanan pesisir, sehingga Semarang dan Demak menjadi daerah dengan tingkat bahaya rob yang tinggi (Marfai and King, 2008a; Abidin et al., 2011; Marfai et al., 2014). Kedua, dari aspek geospasial, kluster ini mewakili Kompleks Teluk Semarang–Jepara. Karakteristik ini membedakannya dari segmen pantai lurus di wilayah barat. Kondisi cekungan teluk memiliki dampak penting terhadap dinamika laut. Topografi pesisir yang berbentuk cekungan dapat menyebabkan gelombang pasang terpantul dan menyebar, sehingga air laut berpotensi terkumpul dan memperkuat genangan di wilayah pesisir (Takagi et al., 2016; Susanto et al., 2021).

Penelitian ini memodelkan fenomena bahaya banjir rob yang terjadi akibat interaksi faktor geologis dan hidrologis di wilayah pesisir. Banjir rob di pesisir utara Jawa Tengah terjadi akibat fenomena pasang surut dan diperparah oleh dinamika hidrologi pesisir. Curah hujan tinggi sebagai masukan hidrologis di daerah urban dan hilir sungai tidak mampu mengalir ke laut. Kondisi ini terjadi karena elevasi muka air laut yang tinggi serta sistem drainase yang tertekan oleh perubahan tata guna lahan dan abrasi pantai, sehingga menciptakan fenomena banjir majemuk

dengan durasi genangan yang lebih lama (Abidin et al., 2011; Takagi et al., 2016; Esteban et al., 2020; Marfai and King, 2008b).

2.1.2 Variabel Dinamis dan Statis Terkait Banjir Rob

Berbagai variabel terkait bahaya banjir rob dikelompokkan berdasarkan karakteristik datanya menjadi kategori dinamis dan statis. Variabel dinamis terdiri dari parameter meteorologi dan oseanografi yang memiliki fluktuasi temporal signifikan dan diproses sebagai data deret waktu *time series*. Komponen ini mencakup arah dan kecepatan angin pada ketinggian 10 meter (u_{10} dan v_{10}) yang memengaruhi pergerakan massa air laut, serta kondisi termodinamika atmosfer seperti titik embun (d_{2m}), suhu udara (t_{2m}), tekanan permukaan laut rata-rata (msl), dan tekanan permukaan (sp) yang berkontribusi pada fluktuasi elevasi air melalui efek invers barometrik. Selain itu, masukan hidrologis dari curah hujan menjadi faktor dinamis krusial yang dapat memicu kondisi banjir majemuk (compound flooding) saat berinteraksi dengan tinggi muka air laut (z) yang menjadi target utama pemodelan (Bevacqua et al., 2019; Voutsdoukas et al., 2018). Di sisi lain, variabel statis atau spasial merupakan data geospasial yang cenderung tetap dalam jangka pendek dan menentukan sensitivitas fisik daratan terhadap genangan. Karakteristik topografi yang meliputi elevasi dan kemiringan lereng (*slope*) berperan dalam menentukan zona akumulasi air, sementara tutupan lahan (*land use/land cover*) memengaruhi kapasitas infiltrasi serta koefisien limpasan permukaan. Salah satu faktor geologis yang sangat kritis di wilayah Pantura Jawa adalah abrasi pantai, yang menyebabkan berkurangnya daratan pesisir secara relatif terhadap permukaan laut sehingga secara signifikan memperparah durasi dan kedalaman banjir rob (Abidin et al., 2011).

Seluruh variabel dinamis dan statis ini diintegrasikan untuk menghasilkan luaran berupa status klasifikasi bahaya, seperti label 'Aman' atau 'Bahaya Banjir Rob', serta untuk mengekstraksi bobot kepentingan fitur (*feature importance*). Penggunaan Jaringan Saraf Tiruan dalam mengolah variabel-variabel tersebut

memungkinkan penentuan kontribusi relatif dari setiap parameter secara objektif dan berbasis data (*data-driven*), yang memberikan akurasi lebih tinggi dalam mengidentifikasi faktor dominan pemicu bencana di lokasi studi dibandingkan dengan metode pembobotan subjektif tradisional (Srivastava and Akhtar, 2025; Hajirahimi and Khashei, 2022).

2.1.3 Pendekatan Prediksi Bahaya Banjir

Prediksi bahaya banjir merupakan proses kompleks yang dipengaruhi oleh dinamika geografi, topografi, dan pola cuaca (Filho et al., 2021; Jazzar, 2021; Sahoo et al., 2021). Pendekatan tradisional yang selama ini mengandalkan analisis probabilitas kini bertransformasi melalui pemanfaatan penambangan data (*data mining*). Metode modern ini mampu mengekstraksi pola tersembunyi melalui teknik prediksi runtun waktu, klasifikasi, serta regresi (Sahoo et al., 2021).

Telah dilakukan studi komparasi antara metode pembobotan subjektif konvensional berbasis *Analytic Hierarchy Process* (AHP) dan pendekatan *data-driven* menggunakan *Machine Learning* (ML) (Hakim et al., 2025). Perbedaan mendasar kedua pendekatan ini terletak pada parameter validasinya:

- AHP: Sangat bergantung pada penilaian pakar yang divalidasi melalui *Consistency Ratio* (CR) untuk memastikan konsistensi logika internal. Pada studi ini, nilai CR yang dihasilkan adalah 0,0547. Namun, metode ini tidak memiliki metrik untuk mengukur akurasi prediktif terhadap data historis.
- ML (JST): Menentukan bobot melalui proses *backpropagation* berdasarkan bukti empiris di lapangan. Kinerja diukur secara objektif menggunakan matriks Akurasi dan *F1-Score*.

Dalam kerangka kerja ini, AHP digunakan sebagai garis dasar (*baseline*) untuk menangkap pengetahuan lokal, sementara JST berfungsi untuk memvalidasi, mengoreksi, dan mengoptimalkan bobot tersebut agar peta bahaya yang dihasilkan benar-benar mencerminkan realitas data historis.

Tiga arsitektur ML diuji untuk mengekstraksi bobot kepentingan fitur: *Logistic Regression* (LR), *Random Forest* (RF), dan JST. Hasil pengujian yang dirangkum pada Tabel 2.1 menunjukkan bahwa JST mengungguli metode lainnya.

Tabel 2.1: Perbandingan Performa Model *Machine Learning*

Model	Akurasi	F1-Score
<i>Logistic Regression</i> (LR)	0.7937	0.7770
<i>Random Forest</i> (RF)	0.7937	0.7831
JST	0,8413	0,8370

Model JST menunjukkan sensitivitas yang lebih tinggi dalam mengidentifikasi wilayah kritis, terutama pada zona bahaya tinggi (Kelas 2). Hal ini sangat krusial bagi mitigasi bencana guna menghindari peremehan (*underestimation*) terhadap ancaman banjir parah.

Temuan kunci studi tersebut menunjukkan adanya divergensi signifikan antara intuisi pakar dan fakta data, di mana korelasi Spearman antara AHP dan JST ditemukan sangat lemah ($\rho = 0,1579$). Sebagai contoh, pakar cenderung memberikan bobot yang sangat tinggi pada ketinggian permukaan air laut (*Sea Level*) hingga 42%, sedangkan hasil ekstraksi ML menunjukkan pengaruh riilnya hanya sekitar 19,76%. Sebaliknya, ML mampu mengidentifikasi variabel seperti kemiringan lereng (*slope*) dan koefisien limpasan sebagai faktor krusial yang sering kali kurang terwakili dalam penilaian kualitatif. Integrasi bobot berbasis ML ke dalam sistem informasi geografis memberikan kecerdasan spasial yang lebih presisi dibandingkan metode konvensional.

Hasil studi literatur juga menunjukkan bahwa metode peramalan runtun waktu klasik yang bersifat univariat, meskipun telah lama digunakan secara efektif, memiliki keterbatasan dalam menjelaskan variabel-variabel yang memengaruhi Y sekaligus mempertimbangkan komponen waktu, sehingga membuka peluang integrasi dengan algoritma JST yang kini mendominasi pendekatan klasifikasi dan regresi. Fenomena ini mengindikasikan bahwa JST memiliki keandalan dan potensi besar untuk dipadukan dengan teknik lain guna meningkatkan akurasi prediksi (Box

et al., 2015; Zhang, 2003; Khashei and Bijari, 2010; Hajirahimi and Khashei, 2022).

2.1.4 Pendekatan Prediksi Runtun Waktu

Prediksi runtun waktu bertujuan memprediksi nilai masa depan berdasarkan data historis (Han et al., 2011; Yan et al., 2018). Pendekatan ini relevan untuk fenomena geofisika seperti banjir yang menunjukkan perilaku deterministik kaotis, yakni sistem nonlinier di mana perubahan kecil pada kondisi awal dapat menyebabkan dampak signifikan (Damle and Yalcin, 2007; Oestreicher, 2007; Robinson, 2009). Model runtun waktu dapat memberikan peringatan dini dengan menganalisis data historis curah hujan atau ketinggian air. Di antara berbagai metode, *Exponential Smoothing* (ES) menjadi pendekatan yang efisien karena kebutuhan komputasi yang rendah. Meskipun demikian, metode ini perlu melibatkan komponen tren dan musiman agar efektif dalam mendukung mitigasi bahaya banjir.

Untuk mendukung pemilihan metode ini, telah dibandingkan dua pendekatan besar: model statistik klasik (TES, *Trigonometric*, *Box-Cox transform*, *ARMA errors*, *Trend*, and *Seasonal components* (TBATS), *Seasonal Autoregressive Integrated Moving Average* (SARIMA), dan *Seasonal and Trend decomposition using Loess* (STL)) dan model *Deep Learning* (*Long Short-Term Memory*/LSTM dan *Gated Recurrent Unit*/GRU), dengan menggunakan data yang sama (Hakim et al., 2026). Hasil evaluasi menunjukkan kontras yang tajam; model statistik klasik, khususnya Penghalusan Eksponensial Tripel (TES), keluar sebagai model terbaik dengan tingkat kesalahan terendah, yaitu *Mean Squared Error* (MSE) sebesar 20,8673 dan *Mean Absolute Percentage Error* (MAPE) 11,11%. Hal ini membuktikan bahwa dinamika permukaan laut memiliki pola musiman dan tren yang sangat stabil sehingga lebih optimal ditangkap oleh metode parametrik tradisional daripada arsitektur saraf yang kompleks. Sebaliknya, model *Deep Learning* seperti LSTM dan GRU mengalami kegagalan generalisasi yang parah dengan nilai MAPE melebihi 80%, dan memberikan prediksi model yang cenderung stagnan. Hal tersebut dapat dilihat hasil evaluasi Tabel 2.2 yang

merupakan rincian performa dari masing-masing metode yang telah dilakukan.

Tabel 2.2: Hasil Evaluasi Performa Pemodelan Peramalan

Nama Model	MSE	MAPE
TES	20.8673	11.11%
STL	32.8393	12.13%
TBATS	28.2709	13.39%
SARIMA	28.9206	14.59%
LSTM	1822.9065	82.60%
GRU	2354.5730	93.93%

Mean Squared Error (MSE) digunakan untuk menyoroti kesalahan dengan varians besar, di mana model TES memiliki nilai terkecil sehingga prediksinya sangat mendekati nilai observasi asli. Sementara itu, *Mean Absolute Percentage Error* (MAPE) memberikan gambaran persentase kesalahan rata-rata yang tidak bergantung pada skala, dan nilai 11,11% yang diperoleh TES dianggap sangat andal untuk data lingkungan. Dari sisi akurasi model statistik, TES bersama dengan STL, TBATS, dan SARIMA menunjukkan stabilitas karena data laut di lokasi studi memiliki karakteristik tren naik yang bertahap serta pola musiman yang konsisten. Sebaliknya, pendekatan berbasis deep learning seperti LSTM dan GRU mengalami kegagalan dengan MAPE lebih dari 80%, yang menegaskan bahwa model berbasis deep learning yang kompleks ini membutuhkan data dalam jumlah masif serta penyetelan hiperparameter yang sangat detail, kondisi yang sering kali tidak tersedia pada data tinggi muka air laut.

2.1.5 Penggunaan Data

Analisis bahaya banjir bergantung pada data geospasial dari Sistem Informasi Geografis (SIG) dan penginderaan jauh. Mayoritas penelitian menggabungkan data stasiun hidrologi (98%) dengan data satelit (97%) yang mencakup informasi curah hujan, topografi, dan tutupan lahan. Dalam hal ini, satelit Sentinel mendominasi penggunaan data dengan kontribusi sebesar 29,8%, diikuti oleh Landsat (12,5%), serta berbagai satelit lainnya (Bowes et al., 2019; Jörges et al., 2021). Dominasi

ini menunjukkan tingginya kepercayaan peneliti terhadap kualitas dan ketersediaan data dari misi Copernicus yang dioperasikan oleh European Space Agency (ESA).

Meskipun demikian, penting untuk membedakan antara data citra satelit mentah dengan produk turunan yang siap pakai. Data dari satelit seperti Sentinel dan Landsat pada dasarnya adalah citra mentah yang masih memerlukan pengolahan lanjutan untuk menghasilkan informasi tematik seperti tutupan lahan. Namun, perkembangan terkini memungkinkan ketersediaan produk turunan berkualitas tinggi yang berbasis pada data tersebut. Sebagai contoh, ESA WorldCover 10 m 2021 v200 adalah peta tutupan lahan global yang dihasilkan dari data Sentinel-1 dan Sentinel-2 (Zanaga et al., 2022). Produk ini menawarkan kemudahan aplikasi karena menyediakan informasi tutupan lahan yang telah terklasifikasi secara akurat dengan resolusi spasial 10 meter, sehingga penggunaannya lebih praktis dibandingkan harus mengolah citra mentah dari awal.

Selain data tutupan lahan, informasi elevasi atau ketinggian permukaan bumi merupakan parameter krusial dalam pemodelan banjir, terutama untuk menentukan arah aliran air, akumulasi aliran, serta wilayah yang berpotensi tergenang. Untuk memenuhi kebutuhan tersebut, penelitian ini memanfaatkan data DEMNAS (*Digital Elevation Model Nasional*) yang dikelola oleh Badan Informasi Geospasial (BIG) (Badan Informasi Geospasial, 2026). DEMNAS merupakan model elevasi digital yang mencakup seluruh wilayah Indonesia dengan resolusi spasial mencapai 0,27 arc-second (sekitar 8,25 meter), jauh lebih detail dibandingkan data DEM global seperti SRTM (30 meter) atau ASTER GDEM. Data ini dibangun dari berbagai sumber, termasuk data IFSAR, TERRASAR-X, dan ALOS PALSAR.

Keunggulan utama DEMNAS terletak pada representasi topografi yang lebih akurat karena menggunakan datum vertikal EGM 2008 (geoid) yang sesuai dengan kondisi geodesi Indonesia (Prasetyo et al., 2022). Beberapa studi menunjukkan bahwa meskipun SRTM memiliki akurasi vertikal sedikit lebih baik (RMSE 5,53 meter), DEMNAS tetap menjadi pilihan utama untuk analisis di wilayah Indonesia karena konsistensi spasialnya dan ketersediaannya yang menyeluruh dengan RMSE sekitar 8,17 meter (Prasetyo et al., 2022). Dalam konteks pemodelan banjir, data

elevasi dari DEMNAS telah banyak diaplikasikan, seperti untuk pemetaan genangan banjir rob di wilayah pesisir (Marfa et al., 2024), analisis potensi banjir pasang surut (Aziz et al., 2024), serta penentuan wilayah terdampak kenaikan muka air laut (Aziz et al., 2024).

2.1.6 Volume Data dalam Penelitian Terdahulu

Model penambangan data memiliki performa lebih baik apabila didukung oleh volume data yang besar (Wu et al., 2014). Berdasarkan kajian terhadap publikasi terdahulu, mayoritas penelitian masih menggunakan data dengan rentang waktu pendek. Penggunaan data di bawah 10 tahun mendominasi sebanyak 59,6% dari 212 makalah Gambar 2.2. Namun, pemanfaatan data dengan rentang lebih dari 10 tahun memiliki potensi lebih besar dalam meningkatkan kualitas pelatihan model. Rentang data yang panjang memungkinkan model mempelajari variasi waktu yang luas dan mengurangi potensi banjir *overfitting*.

2.1.7 Jenis Banjir dan Parameter Bahaya

Prediksi bahaya banjir yang akurat bergantung pada pemahaman faktor pemicu yang dikategorikan sebagai faktor dinamis dan faktor statis. Karakteristik setiap jenis banjir adalah sebagai berikut:

1. Banjir Sungai (76,1%): Dipicu oleh curah hujan tinggi yang berkepanjangan dan peningkatan debit aliran. Faktor statis meliputi topografi dan tata guna lahan di sekitar sungai.
2. Banjir Perkotaan (11,9%): Dipicu oleh hujan dengan intensitas tinggi dalam waktu singkat. Faktor statis utama adalah tingginya koefisien limpasan akibat permukaan kedap air.
3. Banjir Pesisir (6,4%): Meliputi pasang surut astronomis dan gelombang badai (*storm surge*). Faktor statis kritis adalah elevasi daratan yang rendah,

jarak ke pantai, kemiringan lereng, dan limpasan yang dipengaruhi jenis tutupan lahan.

4. Banjir Bandang (5,5%): Terjadi akibat curah hujan ekstrem dalam durasi singkat. Kondisi ini dipengaruhi oleh topografi curam dan tutupan lahan yang minim.

2.1.8 Keaslian Penelitian


Keaslian penelitian ini didasarkan pada celah (*research gap*) di mana penelitian terdahulu cenderung berfokus pada banjir sungai atau menggunakan pendekatan univariat. Penelitian ini memposisikan diri sebagai solusi melalui tiga pilar kebaruan:

1. Fokus pada prediksi runtun waktu di kawasan pesisir sebagai area yang jarang dikaji.
2. Pemanfaatan model hibrida JST-TES untuk mengatasi kelemahan linearitas pada metode klasik.
3. Penerapan model JST secara *data-driven* untuk menghasilkan bobot bahaya banjir secara objektif.

2.2 Landasan Teori

Pada bagian ini disajikan beberapa teori dan pendekatan yang mendasari pengembangan model prediksi banjir rob Gambar 2.3. Bagian ini dimulai dengan pemahaman mengenai dinamika wilayah pesisir serta faktor-faktor yang memicu kerentanan terhadap kenaikan permukaan air laut. Selanjutnya, dipaparkan peran penambangan data (data mining) dalam mengekstraksi informasi dari dataset besar guna menghasilkan klasifikasi bahaya yang akurat.

Secara khusus, bagian ini menguraikan integrasi antara metode statistik konvensional, yaitu Penghalusan Eksponensial Tripel, dengan algoritma kecerdasan



Gambar 2.3: Penelitian Terkait Prediksi Banjir dan Kerangka Konseptual

buatan berupa Jaringan Saraf Tiruan (JST). Sinergi kedua metode ini membentuk pendekatan hibrida sekuensial yang bertujuan untuk mengatasi kompleksitas data deret waktu yang bersifat linear maupun non-linear, sehingga mampu menghasilkan prediksi yang bersifat antisipatif bagi mitigasi bencana di wilayah pesisir.

2.2.1 Daerah Pesisir

Pesisir didefinisikan sebagai wilayah peralihan yang dinamis antara ekosistem daratan dan lautan (Yonvitner and Susanto, 2019). Secara fungsional, batasan wilayah ini ditentukan oleh jangkauan pengaruh fisik keduanya; wilayah daratan di pesisir dicirikan oleh pengaruh sifat laut seperti fluktuasi pasang surut, hembusan angin laut, serta intrusi air asin ke dalam akuifer daratan. Sebaliknya, wilayah laut di zona pesisir dipengaruhi oleh proses alami daratan yang meliputi aliran air tawar dari sungai serta sedimentasi yang membawa material dari hulu ke hilir.

Karakteristik unik dari wilayah pesisir menjadikannya area yang sangat rentan terhadap perubahan lingkungan. Interaksi antara darat dan laut menciptakan ekosistem yang kompleks, namun sekaligus menyimpan potensi bencana yang tinggi, terutama terkait dengan kenaikan permukaan air laut (Abidin et al., 2011; Marfai and King, 2008a). Oleh karena itu, informasi terkait dinamika hidrografi di daerah pesisir menjadi fondasi dalam melakukan pemodelan prediksi bahaya

banjir rob yang akurat (Nayak, 2017). Pengelolaan wilayah ini memerlukan pendekatan terintegrasi yang mempertimbangkan aspek perlindungan alami, seperti hutan mangrove, yang berperan penting dalam meredam energi gelombang dan menjaga stabilitas garis pantai (Saintilan et al., 2014; Yonvitner and Susanto, 2019).

2.2.2 Prediksi dan Bahaya Banjir

Prediksi banjir merupakan komponen vital dalam manajemen bencana yang bertujuan untuk menghasilkan peta bahaya sebagai dasar pengambilan keputusan mitigasi. Secara teoretis, Bahaya (*hazard*) merupakan subset atau komponen pembentuk dari Risiko (*risk*). Berdasarkan kerangka kerja *United Nations Office for Disaster Risk Reduction* (UNDRR) dan *Intergovernmental Panel on Climate Change* (IPCC) (UNDRR, 2025; Field et al., 2012; Pörtner et al., 2022), hubungan antara risiko dan bahaya dirumuskan dalam persamaan Equation 2.1.

$$Risk = Hazard \times Exposure \times Vulnerability \quad (2.1)$$

Dalam konteks ini, bahaya *hazard* mengacu pada potensi ancaman fisik atau fenomena alam yang dapat menimbulkan dampak merusak terhadap kehidupan dan properti. Konsekuensi teoretis dari pembatasan pada aspek hazard dalam penelitian ini adalah fokus mendalam pada probabilitas dan intensitas fisik kejadian banjir tanpa melibatkan variabel sosial-ekonomi seperti kerentanan (*vulnerability*) dan keterpaparan (*exposure*). Penyusunan indeks bahaya dilakukan melalui teknik agregasi terbobot dari berbagai parameter geofisik. Secara matematis, nilai Bahaya (*H*) dirumuskan sebagai jumlah perkalian antara skor variabel dengan bobotnya masing-masing (Awah et al., 2024; CSU, 2025; Bukhari et al., 2025; Hutaaruk et al., 2020) yang dirumuskan dalam persamaan Equation 2.2.

$$H = \sum_{i=1}^n w_i \times s_i \quad (2.2)$$

Di mana:

- H = Indeks Bahaya (Hazard Index).
- w_i = Bobot variabel ke- i yang dihasilkan secara objektif melalui ekstraksi bobot kepentingan fitur yang dihasilkan melalui algoritma Jaringan Saraf Tiruan.
- s_i = Skor ternormalisasi dari parameter fisik seperti kemiringan lereng, ketinggian (elevasi), koefisien limpasan, dan tinggi muka air laut.

Konsep bahaya bersifat dinamis karena sangat dipengaruhi oleh anomali perubahan iklim yang memicu kenaikan air laut serta perubahan penggunaan lahan yang meningkatkan koefisien limpasan. Oleh karena itu, akurasi penentuan bobot (w_i) menjadi krusial agar model tetap sensitif terhadap karakteristik lokal wilayah studi (Bukhari et al., 2025; Hutaaruk et al., 2020).

2.2.3 Kenaikan Permukaan Air Laut

Kenaikan permukaan air laut (*Sea Level Rise*) merupakan fenomena global yang dipicu oleh ekspansi termal massa air laut dan kontribusi signifikan dari mencairnya lapisan es di daratan. Berdasarkan laporan terbaru IPCC (AR6), laju kenaikan rata-rata permukaan laut global terus menunjukkan akselerasi, meningkat menjadi 3,7 mm/tahun (atau secara spesifik 3,69 mm/tahun) pada periode 2006–2018 (Fox-Kemper et al., 2021). Akselerasi ini memperparah frekuensi banjir rob dan meningkatkan jangkauan destruktif gelombang badai yang secara langsung mengancam integritas infrastruktur di wilayah pesisir (Vousdoukas et al., 2018). Selain dampak fisik berupa genangan, intrusi air asin ke dalam akuifer daratan turut mengancam ketersediaan sumber air tawar bagi populasi pesisir (Soni, 2012). Meskipun ekosistem mangrove dapat berfungsi sebagai peredam alami, kemampuannya terbatas pada laju adaptasi terhadap elevasi air laut yang terus berubah (Saintilan et al., 2014). Dalam konteks tersebut, prediksi tinggi muka air laut menjadi instrumen krusial dalam manajemen potensi bencana. Kemampuan untuk memproyeksikan fluktuasi muka air di masa depan secara akurat sangat

diperlukan untuk memberikan peringatan dini yang efektif dan menyusun strategi adaptasi jangka panjang. Prediksi yang presisi memungkinkan identifikasi area rawan genangan secara lebih dini, sehingga langkah-langkah mitigasi—baik yang bersifat struktural seperti tanggul laut maupun non-struktural seperti perencanaan tata ruang—dapat diimplementasikan secara optimal. Tanpa adanya model prediksi yang andal, wilayah pesisir akan terus menghadapi ketidakpastian tinggi yang meningkatkan potensi kerugian ekonomi dan sosial akibat bencana banjir yang tidak terantisipasi.

2.2.4 Penambangan Data

Penambangan data (data mining) merupakan proses sistematis untuk mengekstraksi pengetahuan, menemukan pola, serta mengidentifikasi hubungan yang signifikan dari kumpulan data berskala besar (Larose and Larose, 2014). Sebagai disiplin ilmu yang bersifat interdisipliner, bidang ini mengintegrasikan metodologi statistik, kecerdasan buatan, dan manajemen basis data untuk mengubah data mentah menjadi informasi yang berharga (Han et al., 2011). Dalam konteks analisis bahaya banjir, pendekatan data-driven menjadi esensial karena mampu menangani kompleksitas data lingkungan yang bersifat non-linear dan multivariat tanpa bergantung sepenuhnya pada asumsi fisik yang kaku.

Pemanfaatan penambangan data dalam penelitian ini mencakup dua pilar utama analisis prediktif:

1. **Klasifikasi:** Digunakan untuk mengategorikan status potensi wilayah, seperti label '*Aman*' atau '*Bahaya Banjir Rob*', berdasarkan fitur-fitur geospasial dan lingkungan (Han et al., 2011). Teknik ini memungkinkan identifikasi zona rentan secara objektif melalui pembelajaran pola historis kejadian banjir.
2. **Peramalan Runtun Waktu (Time Series Forecasting):** Berfokus pada proyeksi nilai numerik spesifik di masa depan, seperti tinggi muka air laut atau intensitas curah hujan. Peramalan ini menjadi komponen vital dalam

sistem peringatan dini karena memberikan dimensi temporal terhadap ancaman banjir.

Efektivitas penambangan data sangat bergantung pada volume dan kualitas data yang digunakan; penggunaan data dengan rentang waktu panjang (di atas 10 tahun) secara signifikan dapat meningkatkan akurasi pelatihan model dan mengurangi potensi *overfitting*. Dengan menggabungkan kekuatan statistik untuk menangkap tren dan musiman serta kecerdasan buatan untuk pemetaan hubungan variabel yang kompleks, penambangan data menyediakan landasan bagi strategi mitigasi bencana yang bersifat antisipatif dan berbasis bukti empiris.


2.2.5 Jaringan Saraf Tiruan (JST)

Jaringan Saraf Tiruan (JST) atau *Artificial Neural Networks* (ANN) adalah model komputasi non-linear yang dirancang dengan meniru struktur serta mekanisme transmisi sinyal pada sistem saraf biologis manusia (Mallot, 2024). Dalam penelitian ini, digunakan arsitektur *Multi-Layer Perceptron* (MLP) yang terdiri dari lapisan input, satu atau lebih lapisan tersembunyi (*hidden layers*), dan lapisan output yang saling terhubung melalui neuron (Gambar 2.4).

JST berperan sebagai pemeta hubungan non-linear yang kompleks antara fitur input (X)—seperti parameter curah hujan, komponen angin, dan tekanan udara—dengan target output (Y) yang berupa label klasifikasi bahaya banjir. Keunggulan utama JST dibandingkan model statistik tradisional adalah kemampuannya dalam menangani data lingkungan yang memiliki volatilitas tinggi tanpa memerlukan asumsi distribusi data yang ketat.

Mekanisme Feed-forward

Arsitektur MLP beroperasi berdasarkan prinsip *feed-forward*, di mana informasi mengalir satu arah dari lapisan input menuju output. Setiap neuron pada *hidden layer* menerima input dari lapisan sebelumnya, yang kemudian dikalikan dengan bobot (w) dan ditambah dengan konstanta bias (b). Hasil penjumlahan linear ini



Gambar 2.4: Diagram Arsitektur Jaringan Saraf Tiruan (ANN) yang menunjukkan aliran data dari input ke output ((Shutterstock, 2024))

kemudian ditransformasikan melalui fungsi aktivasi non-linear. Secara matematis, proses pada satu neuron dapat dinyatakan sebagai:

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.3)$$

Di mana x_i adalah fitur input ke- i , dan z adalah nilai prainput untuk fungsi aktivasi.

Fungsi Aktivasi

Fungsi aktivasi menentukan apakah sebuah neuron harus aktif (*fired*) dan berkontribusi pada output akhir. Sesuai dengan implementasi model dalam penelitian ini, digunakan dua jenis fungsi aktivasi:

1. **Rectified Linear Unit (ReLU):** Digunakan pada lapisan tersembunyi untuk mempercepat konvergensi dan mengatasi fenomena *vanishing*

gradient.

$$f(z) = \max(0, z) \quad (2.4)$$

2. **Softmax:** Digunakan pada lapisan keluaran untuk menghasilkan probabilitas distribusi kelas, sehingga hasil prediksi dapat diinterpretasikan sebagai tingkat risiko atau kategori bahaya.

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (2.5)$$

Optimasi dan Fungsi Kerugian

Pembelajaran pada JST dilakukan melalui mekanisme *backpropagation* untuk meminimalkan galat antara prediksi model dan nilai aktual. Model ini menggunakan fungsi kerugian *Categorical Cross-Entropy* (L):

$$L(y, \hat{y}) = - \sum_{j=1}^K y_j \log(\hat{y}_j) \quad (2.6)$$

Di mana y_j adalah label aktual dalam format *one-hot encoding*. Proses pembaruan bobot dilakukan menggunakan algoritma **Adam** (*Adaptive Moment Estimation*), yang menghitung laju pembelajaran adaptif berdasarkan estimasi momen pertama (m_t) dan kedua (v_t) dari gradien Kingma and Ba (2014).

Interpretabilitas dan Pembobotan Fitur

Selain kemampuan prediksi, proses pelatihan pada JST menghasilkan nilai bobot yang mencerminkan kontribusi relatif dari setiap fitur input terhadap keputusan klasifikasi. Ekstraksi nilai bobot ini sangat penting untuk mengidentifikasi *feature importance*. Dengan menganalisis besaran bobot pada koneksi saraf, penelitian ini dapat menentukan variabel atmosferik atau oseanografik mana yang paling dominan dalam memicu kejadian banjir di wilayah pesisir. Pendekatan ini memberikan dasar bagi pembobotan yang lebih objektif dan berbasis data (*data-driven*), sebagai

alternatif yang lebih kuat dibandingkan metode konvensional seperti *Analytical Hierarchy Process* (AHP) yang sering kali bersifat subjektif karena bergantung pada penilaian pakar (Al Kuisi et al., 2024; Srivastava and Akhtar, 2025).

2.2.6 Penghalusan Eksponensial Tripel

Metode Penghalusan Eksponensial Tripel (*Holt-Winters* atau *Triple Exponential Smoothing*, TES) merupakan pengembangan dari metode penghalusan tunggal dan ganda. Berbeda dengan pendahulunya yang terbatas pada data stasioner atau tren linier, TES dirancang khusus untuk menangani data deret waktu yang mengandung tiga komponen sekaligus: level, tren, dan musiman (*seasonality*) Holt (1957); Winters (1960); Hyndman and Athanasopoulos (2021); Chatfield (2000). Karakteristik ini membuat TES sangat efektif untuk meramalkan data dengan pola berulang pada periode tertentu, seperti bulanan atau tahunan.

Penamaan eksponensial pada metode ini merujuk pada prinsip pembobotan datanya, di mana kontribusi data masa lalu terhadap prediksi masa depan meluruh secara geometris. Dalam keluarga *exponential smoothing*, bobot diturunkan mengikuti fungsi peluruhan $w_t = \alpha(1 - \alpha)^t$ sehingga data terbaru diberikan bobot terbesar Winters (1960); Hyndman and Athanasopoulos (2021). Sebelum membahas formulasi TES lebih lanjut, berikut disajikan tinjauan singkat mengenai konsep eksponen dan eksponensial yang melandasinya.

Konsep Eksponen dan Eksponensial


Eksponen dan eksponensial adalah dua konsep matematis yang mendasari logika pemulusan dalam TES. Eksponen merujuk pada operasi perpangkatan a^n yang menyatakan perkalian berulang bilangan pokok a sebanyak n kali. Sementara itu, eksponensial merujuk pada fungsi dinamis $f(x) = a^x$, di mana variabel bebas berada pada posisi pangkat (Chatfield, 2000; Hyndman and Athanasopoulos, 2021).

Karakteristik utama fungsi eksponensial adalah laju perubahannya yang sebanding dengan nilai fungsi itu sendiri, sebuah sifat yang secara matematis

dinyatakan melalui turunan $f'(x) = f(x) \ln a$ (Chatfield, 2000; Hyndman and Athanasopoulos, 2021). Hal ini menghasilkan pola pertumbuhan akseleratif atau peluruhan dekseleratif tergantung pada nilai basisnya. Perbandingan ringkas antara keduanya disajikan pada Tabel 2.3 dan grafik Gambar 2.5.

Tabel 2.3: Perbandingan Konsep Eksponen dan Eksponensial

Aspek	Eksponen	Eksponensial
Definisi	Operasi perpangkatan	Fungsi dengan variabel pada eksponen
Bentuk Umum	a^n	$f(x) = a^x$
Output	Nilai tunggal (skalar)	Pola perubahan (dinamis)
Posisi Variabel	Berada pada basis (misal: x^3)	Berada pada pangkat (misal: 3^x)



Gambar 2.5: Visualisasi Perbandingan Konsep Eksponen vs Eksponensial

Dalam konteks peramalan, fungsi eksponensial digunakan untuk menentukan bobot melalui parameter pemulusan $\alpha, \beta, \gamma \in [0, 1]$. Meskipun secara teoretis pertumbuhan kontinu sering dikaitkan dengan bilangan Euler $e \approx 2.71828$ melalui basis alami, TES menggunakan parameter diskrit yang dioptimasi untuk mencerminkan karakteristik historis data secara spesifik Holt (1957); Winters

(1960); Hyndman and Athanasopoulos (2021).

Persamaan Matematis Komponen

Pada model TES aditif, fluktuasi musiman diasumsikan relatif konstan terhadap level. Sesuai dengan formulasi Equation 2.7 (Kamisan et al., 2023), pembaruan komponen level L_t menggabungkan observasi aktual yang dide-seasonalisasi dengan estimasi periode sebelumnya.

$$L_t = \alpha(y_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.7)$$

di mana y_t adalah observasi aktual dan m adalah panjang periode musiman. Selanjutnya, arah perubahan data ditangkap oleh komponen tren T_t yang diperbarui berdasarkan selisih level antar periode sesuai (Equation 2.8):

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2.8)$$

Adapun fluktuasi periodik direpresentasikan oleh komponen musiman S_t yang dihitung dengan membandingkan nilai aktual terhadap level saat ini (Equation 2.9):

$$S_t = \gamma(y_t - L_t) + (1 - \gamma)S_{t-m} \quad (2.9)$$

Integrasi ketiga komponen ini memungkinkan TES untuk beradaptasi terhadap perubahan pola data secara dinamis.

Persamaan Prediksi

Nilai peramalan untuk h periode ke depan ($\hat{y}_{t+h}$) dihitung dengan menjumlahkan proyeksi level, tren linier, dan komponen musiman yang relevan (Equation 2.10):

$$\hat{y}_{t+h} = L_t + hT_t + S_{t-m+h_m^+} \quad (2.10)$$

Dalam persamaan tersebut, indeks musiman dikontrol oleh notasi $h_m^+ = [(h -$

1) $(\text{mod } m)] + 1$ untuk memastikan bahwa fase musiman yang digunakan dalam prediksi tetap sinkron dengan siklus datanya.

Optimasi Parameter Menggunakan L-BFGS-B

Akurasi hasil peramalan TES sangat bergantung pada penentuan nilai optimal α , β , dan γ . Parameter tersebut dicari dengan meminimalkan fungsi objektif *Mean Squared Error* (MSE) yang didefinisikan pada Persamaan (2.17):

$$MSE(\alpha, \beta, \gamma) = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (2.11)$$

Mengingat sifat fungsi MSE yang nonlinier terhadap parameter, digunakan algoritma L-BFGS-B (*Limited-memory Broyden–Fletcher–Goldfarb–Shanno with Boundary constraints*). Algoritma ini dipilih karena efisiensinya dalam menangani batasan interval $[0, 1]$ secara ketat dan konvergensi yang lebih cepat dibandingkan metode *gradient descent* konvensional (Byrd et al., 1995). Proses optimasi dilakukan secara iteratif untuk menghasilkan vektor parameter yang memberikan galat terkecil bagi model.

Prosedur Penerapan Metode

Secara sistematis, implementasi TES untuk peramalan data deret waktu mengikuti prosedur berikut:

1. Menentukan panjang periode musiman (m) berdasarkan frekuensi data.
2. Melakukan inisialisasi nilai awal untuk level (L_0), tren (T_0), dan musiman ($S_0, \dots, S_{m-1}$).
3. Mencari parameter pemulusan α, β, γ melalui optimasi L-BFGS-B untuk meminimalkan nilai MSE pada Persamaan (2.17).
4. Memperbarui nilai komponen secara rekursif menggunakan Persamaan (2.7) hingga Persamaan (2.9) untuk seluruh data historis.

5. Menghasilkan proyeksi masa depan $\hat{y}_{t+h}$ dengan menerapkan Persamaan (2.10).

2.2.7 Pendekatan Hibrida

Pendekatan hibrida merupakan strategi pemodelan yang mengintegrasikan dua atau lebih metode yang berbeda untuk mengatasi keterbatasan yang dimiliki oleh model tunggal (*standalone model*). Filosofi utama di balik pendekatan ini adalah asumsi bahwa data runtun waktu di dunia nyata, seperti parameter oseanografik dan atmosferik, sering kali memiliki struktur kompleks yang terdiri dari komponen linear dan non-linear secara simultan (Zhang, 2003). Model statistik klasik seperti *Triple Exponential Smoothing* (TES) sangat efektif dalam menangkap pola linear dan musiman, namun sering kali gagal memetakan dinamika non-linear yang kaotis. Sebaliknya, algoritma kecerdasan buatan seperti *Neural Network* memiliki fleksibilitas tinggi dalam menangkap pola non-linear namun dapat berperforma buruk jika data mengandung tren atau musiman yang kuat tanpa pra-pemrosesan yang tepat (Khashei and Bijari, 2010).

Secara umum, integrasi model dalam literatur peramalan dapat diklasifikasikan ke dalam tiga kategori utama:

1. Hibrida Sejajar (*Parallel Hybrid*): Beberapa model dijalankan secara independen, dan hasil akhirnya digabungkan melalui mekanisme pembobotan atau rata-rata.
2. Hibrida Berbasis Dekomposisi (*Decomposition-based Hybrid*): Data asli dipecah menjadi sub-komponen (misalnya tren, musiman, dan residu), di mana masing-masing komponen dimodelkan secara terpisah sebelum digabungkan kembali.
3. Hibrida Sekuensial (*Sequential Hybrid*): Model disusun secara bertahap di mana keluaran dari satu model menjadi masukan bagi model berikutnya.

2.2.8 Pendekatan Hibrida Sekuensial: Penghalusan Eksponensial Tripel dan Jaringan Saraf Tiruan

Strategi *Sequential Hybrid Forecasting* sebagai sebuah pendekatan dua tahap yang menggabungkan kekuatan model statistik deret waktu dan kecerdasan buatan (Perlin et al., 2025; Liu et al., 2024; Green et al., 2024; listing, 2025). Tahap pertama difokuskan pada peramalan fitur independen ($u_{10}, v_{10}, d_{2m}, t_{2m}, msl, sp$) menggunakan metode TES atau Holt-Winters. Pemilihan TES didasarkan pada kemampuannya yang robust dalam menangkap tren dan pola musiman secara simultan (Kamisan et al., 2023; Chen and Wang, 2022). Hasil dari tahap ini adalah proyeksi fitur yang mencerminkan kondisi masa depan berdasarkan data historis.

Tahap kedua menggunakan hasil proyeksi fitur tersebut sebagai input bagi model JST. Dalam skema sekuensial ini, JST berfungsi sebagai pemeta hubungan non-linear yang kompleks antara variabel atmosferik dan ketinggian muka air laut (z). Penggunaan data hasil ramalan (*forecasted features*) sebagai input JST memungkinkan model untuk bersifat antisipatif, memberikan gambaran prediksi di masa depan meskipun data observasi aktual belum tersedia (Chen and Wang, 2022; Shakila and Shaik, 2025; Hajirahimi and Khashei, 2022).

Secara filosofis, integrasi ini merujuk pada prinsip bahwa data runtun waktu di dunia nyata seringkali tidak dapat diselesaikan secara optimal oleh satu model tunggal (Zhang, 2003; Khashei and Bijari, 2010). Konsep dasar model hibrida ini dirumuskan sebagai kombinasi antara komponen linear (L_t) dan komponen non-linear (N_t) dalam Persamaan (2.12).

$$Y_t = L_t + N_t \quad (2.12)$$

Dukungan riset terdahulu (*State of the Art/SOTA*) memperkuat pemilihan arsitektur ini dibandingkan model tunggal atau model kompleks lainnya:

- Keunggulan Sekuensial: Penelitian oleh Chen and Wang (2022) dan Kamisan et al. (2023) menunjukkan bahwa penggunaan hasil ramalan TES sebagai

input model kecerdasan buatan secara signifikan meningkatkan akurasi prediksi parameter lingkungan dibandingkan metode univariat.

- Kelemahan Deep Learning pada Data Terbatas: Meskipun arsitektur saraf kompleks seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) populer, riset menunjukkan model tersebut sering mengalami kegagalan generalisasi atau *overfitting* pada dataset lokal yang terbatas dengan nilai MAPE melebihi 80% (Hajirahimi and Khashei, 2022; Chen, 2021).
- Perbandingan dengan Model Ensemble: Dalam uji komparatif, arsitektur berbasis JST terbukti mengungguli algoritma *ensemble* populer seperti *Random Forest* (RF) dalam hal akurasi klasifikasi dan regresi untuk variabel bahaya banjir pesisir (Hakim et al., 2023; Srivastava and Akhtar, 2025).

Sinergi sekuensial ini secara signifikan mengurangi beban komputasi pada model saraf tiruan karena struktur data input sudah terorganisir oleh komponen statistik, sehingga meminimalisir akumulasi galat (*error propagation*) dan meningkatkan akurasi prediksi jangka panjang bagi mitigasi bencana pesisir (Perlin et al., 2025; Hajirahimi and Khashei, 2022; Zhang, 2003).

2.2.9 Metrik Evaluasi Performa Klasifikasi

Evaluasi performa pada model klasifikasi bertujuan untuk mengukur efektivitas algoritma dalam memetakan data masukan ke dalam kategori yang tepat. Berbeda dengan metrik peramalan yang mengukur galat numerik, metrik klasifikasi didasarkan pada perbandingan antara label prediksi dengan label aktual yang direpresentasikan dalam sebuah matriks kontingensi (Sokolova and Lapalme, 2009).

1. *Confusion Matrix* *Confusion Matrix* merupakan tabel dasar yang digunakan untuk menggambarkan kinerja model klasifikasi secara detail. Matriks ini terdiri dari empat parameter utama, yaitu:

- *True Positive* (TP): Data positif yang diprediksi benar sebagai positif.
- *True Negative* (TN): Data negatif yang diprediksi benar sebagai negatif.
- *False Positive* (FP): Data negatif yang salah diprediksi sebagai positif (*Type I Error*).
- *False Negative* (FN): Data positif yang salah diprediksi sebagai negatif (*Type II Error*).

2. *Akurasi (Accuracy)* Akurasi merupakan rasio prediksi benar (positif dan negatif) terhadap keseluruhan data. Metrik ini memberikan gambaran umum mengenai performa model, namun dapat menjadi bias jika dataset memiliki ketidakseimbangan kelas (*imbalanced data*) (Powers, 2011). Persamaan akurasi didefinisikan pada Persamaan 2.13.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.13)$$

3. *Presisi (Precision)* Presisi atau *positive predictive value* mengukur tingkat keakuratan model dalam memprediksi kelas positif. Metrik ini sangat krusial dalam skenario di mana kesalahan *False Positive* memiliki dampak yang merugikan (Tharwat, 2018). Rumus presisi ditunjukkan pada Persamaan 2.14:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.14)$$

4. *Recall (Sensitivity)* *Recall* mengukur kemampuan model dalam menemukan kembali seluruh instansi dari kelas positif yang ada dalam dataset. Dalam mitigasi bencana, *recall* sering kali dianggap lebih penting daripada presisi karena kegagalan dalam mendeteksi kejadian nyata (*False Negative*) dapat berakibat fatal (Sokolova and Lapalme, 2009). Persamaan *recall* dirumuskan pada Persamaan 2.15.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.15)$$

5. F1-Score *F1-Score* merupakan rata-rata harmonik antara presisi dan *recall*. Metrik ini memberikan keseimbangan antara kedua parameter tersebut dan sering digunakan sebagai metrik tunggal untuk mengevaluasi model pada dataset yang tidak seimbang (Powers, 2011; Tharwat, 2018). Persamaan *F1-Score* didefinisikan pada Persamaan (2.16):

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.16)$$

2.2.10 Metrik Evaluasi Performa Peramalan Runtun Waktu

Evaluasi performa merupakan tahapan krusial dalam pemodelan runtun waktu untuk mengukur sejauh mana kemampuan model dalam menggeneralisasi data dan meminimalkan selisih antara nilai prediksi dengan nilai aktual. Dalam penelitian ini, efektivitas model hibrida sekuensial diukur menggunakan tiga metrik statistik standar, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) (Hyndman and Athanasopoulos, 2018).

Pemilihan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) dalam penelitian ini didasarkan pada karakteristik unik masing-masing metrik yang saling melengkapi dalam memberikan interpretasi galat model secara komprehensif; di mana MSE berfungsi memberikan penalti berat pada galat yang signifikan karena sifat kuadratnya sehingga sensitif terhadap *outlier*, yang kemudian dilengkapi oleh RMSE untuk mengembalikan interpretasi nilai galat tersebut ke dalam unit fisik asli (seperti meter) agar lebih mudah dipahami secara praktis, sementara MAPE hadir untuk memberikan konteks relatif dalam bentuk persentase yang tidak dipengaruhi oleh skala data sehingga memungkinkan perbandingan performa model yang lebih objektif pada berbagai kondisi dataset.

Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE)

MSE merupakan metrik yang menghitung rata-rata kuadrat selisih antara nilai

observasi aktual (y_i) dan nilai prediksi ($\hat{y}_i$). Penggunaan kuadrat pada metrik ini memberikan penalti yang lebih besar terhadap galat yang signifikan, sehingga sangat efektif untuk mengidentifikasi keberadaan *outlier* dalam data (Chai and Draxler, 2014). Persamaan MSE didefinisikan dinyatakan dalam Persamaan (2.17):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.17)$$

Meskipun MSE efektif dalam proses optimasi (seperti pada fungsi objektif L-BFGS-B), satuannya tidak setara dengan satuan data asli karena adanya operasi kuadrat. Oleh karena itu, *Root Mean Squared Error* (RMSE) digunakan untuk mengembalikan dimensi galat ke dalam satuan asli data (misalnya dalam meter atau sentimeter untuk tinggi muka air laut), sehingga lebih mudah untuk diinterpretasikan secara fisik (Hodson, 2022). RMSE dinyatakan dalam Persamaan (2.18):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.18)$$

Mean Absolute Percentage Error (MAPE)

Berbeda dengan MSE dan RMSE yang bersifat absolut, MAPE memberikan gambaran mengenai galat dalam bentuk persentase relatif terhadap nilai aktual. Metrik ini sangat berguna untuk membandingkan performa model pada dataset dengan skala yang berbeda atau untuk memberikan informasi kepada pemangku kepentingan mengenai tingkat akurasi model dalam bahasa yang lebih intuitif (Lewis, 1982a; De Myttenaere et al., 2016). Persamaan MAPE dirumuskan dinyatakan dalam Persamaan (2.19):

$$\text{MAPE} = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100\% \quad (2.19)$$

Dalam Persamaan (2.17), (2.18), dan (2.19), variabel n menunjukkan jumlah sampel data, y_i adalah nilai aktual muka air laut pada waktu ke- i , sedangkan $\hat{y}_i$

merupakan nilai hasil prediksi model. Model dikatakan memiliki performa yang sangat baik jika nilai dari ketiga metrik tersebut mendekati nol.



SEKOLAH PASCASARJANA