

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Bencana Alam

Terminologi bahasa Inggris dalam kamusnya mengatakan, bencana bisa disebut sebagai "disaster" yang berasal dari bahasa latin *dis* dan *aster*. Kata *dis* berarti buruk atau tidak nyaman, sedangkan *aster* berarti bintang. Secara harfiah, *disaster* berarti menjauh dari lintasan bintang atau dapat diartikan sebagai kejadian yang dipengaruhi oleh konfigurasi astrologi yang tidak menguntungkan (Heryana, 2020). Referensi lain menjelaskan bahwa bencana terjadi akibat posisi bintang dan planet yang tidak diinginkan (Coppola, 2006; Etkin, 2014). Gunn (2012) dalam *Dictionary of Disaster Medicine and Humanitarian Relief* mengatakan bahwa bencana merupakan kerusakan ekologis yang meluas, baik dari segi fisik maupun dalam hubungan fungsional antara manusia dan lingkungannya, yang bisa disebabkan oleh faktor alam atau ulah manusia. Bencana ini dapat berupa peristiwa besar yang tampak jelas atau bersifat lambat dan tersembunyi seperti kekeringan. Skalanya sedemikian besar hingga tidak dapat ditanggulangi oleh sumber daya yang tersedia, sehingga komunitas terdampak memerlukan upaya luar biasa dalam penanganannya, bahkan mungkin memerlukan bantuan dari masyarakat internasional.

Setiap bencana memiliki dampak atau magnitudo yang diakibatkannya. Berdasarkan karakteristik ini, tidak semua kejadian yang merugikan dapat dikategorikan sebagai bencana. Terdapat beberapa perbedaan antara peristiwa, bencana, dan malapetaka besar. Klasifikasi bencana berdasarkan penyebabnya terbagi menjadi tiga kategori, yaitu bencana alam, bencana industri, dan bencana akibat tindakan manusia (Taylor, 1987). Bencana alam adalah peristiwa atau rangkaian kejadian yang menimbulkan ancaman serta mengganggu kehidupan masyarakat,

yang terjadi secara alami atau dipicu oleh faktor-faktor alam. Dampak yang ditimbulkannya sangat signifikan, mencakup korban jiwa, kerusakan lingkungan, kerugian material, serta dampak psikologis bagi masyarakat yang terdampak. Diperkirakan kejadian bencana alam akan terus meningkat disebabkan oleh beberapa faktor seperti pemanasan global (*global warming*), bertambahnya variasi jenis penyakit, perubahan musim, dan variasi siklus alam seperti *solar maxima*, gempa bumi dan aktivitas vulkanik yang menjadi bahasan pada penelitian kali ini. Gempa bumi termasuk kedalam klasifikasi bencana alam yang diakibatkan oleh kejadian geofisika (*geo-physical disaster*) yang disebabkan oleh energi yang dihasilkan dari berbagai kejadian geofisika (Etkin, 2014b; Hogan & Burstein, 2007).

2.1.2 Gempa Bumi

Seorang seismolog Reid berpendapat tentang teori *Elastic Rebound* menyatakan bahwa peristiwa gempa bumi disebabkan oleh pelepasan energi elastis batuan karena adanya deformasi batuan yang terjadi di litosfer. Terjadinya deformasi batuan disebabkan oleh tekanan (*stress*) dan tarikan (*strain*) yang terus menerus pada lapisan bumi. Pada saat deformasi batuan mencapai batasnya, akan terjadi pergeseran dan patahan yang tiba-tiba (Bullen & Bolt, 1985). Gempa bumi (*earthquake*) adalah fenomena getaran atau guncangan yang terjadi pada permukaan bumi akibat pergeseran mendadak lapisan batuan di kerak bumi, yang biasanya disebabkan oleh pergerakan lempeng tektonik (Wahyuningsih & Abadi, 2024). Gempa bumi terjadi ketika energi yang tersimpan di dalam bumi dilepaskan secara tiba-tiba, mengakibatkan patahnya lapisan batuan di kerak bumi. Energi ini, yang terakumulasi akibat pergerakan lempeng tektonik, menyebar ke segala arah dalam bentuk gelombang gempa, sehingga efeknya dapat dirasakan hingga ke permukaan bumi (BMKG, 2023).

Energi yang dihasilkan dari gempa berasal dari titik pusat yang disebut hiposentrum. Hiposentrum adalah lokasi sumber gempa di kedalaman tertentu di dalam bumi (Prathivi, 2020). Kekuatan gempa sangat dipengaruhi oleh letak hiposentrum ini, yang berada di dalam lapisan bumi (*litosfer*). Sementara itu, titik di permukaan bumi yang berada tepat di atas hiposentrum disebut episentrum, yang merupakan area pertama yang menerima energi dari hiposentrum dan biasanya mengalami dampak dan kerusakan paling parah. Ketika hiposentrum melepaskan energi gempa, getaran yang terbentuk menyebar ke segala arah dalam bentuk gelombang seismik, yang terdiri dari gelombang primer dan sekunder. Getaran ini juga menjalar di permukaan bumi dalam bentuk gelombang panjang. Tingkat kerusakan yang ditimbulkan oleh gempa sangat dipengaruhi oleh sejumlah faktor, termasuk kekuatan gempa, kedalaman hiposentrum, jenis batuan yang terkena gempa, besarnya pergeseran batuan, durasi getaran, kerentanan bangunan, kondisi tanah, dan kualitas bangunan (Elfritri et al., 2016).

2.1.3 Mitigasi Bencana

Mitigasi bencana merupakan serangkaian upaya untuk mengurangi resiko bencana, baik melalui pembangunan fisik maupun penyadaran dan peningkatan kemampuan menghadapi ancaman bencana (UU No. 24 Tahun 2007). Bencana alam seperti gempa bumi, tsunami, banjir, tanah longsor, dan letusan gunung berapi adalah peristiwa yang kerap terjadi. Indonesia, sebagai negara kepulauan, berada di pertemuan tiga lempeng tektonik dunia, yaitu lempeng Hindia-Australia di bagian selatan, lempeng Eurasia di barat, dan lempeng Pasifik di timur (BNPB, 2020). Mitigasi bencana merupakan langkah penting sebagai pijakan utama dalam manajemen bencana dengan tujuan utama untuk mengurangi atau mencegah korban jiwa dan kerugian yang mungkin terjadi, fokus utama harus diberikan pada tahap sebelum bencana terjadi, terutama melalui kegiatan yang bertujuan untuk meredam dampak, yang dikenal sebagai

mitigasi. Prinsipnya, mitigasi perlu dilakukan untuk semua jenis bencana, baik bencana alam maupun bencana akibat ulah manusia (Wekke, 2021).

Mitigasi bertujuan untuk mengurangi potensi kerugian, baik korban jiwa maupun harta benda, yang dapat memengaruhi kehidupan dan aktivitas manusia. Merancang rencana atau strategi mitigasi yang efektif dan tepat sasaran, perlu dilakukan kajian risiko. Mitigasi bencana sebaiknya dilakukan secara rutin dan berkelanjutan (*sustainable*), sehingga langkah-langkah mitigasi terus berkembang dan dapat diterapkan dalam jangka panjang. Kementerian Dalam Negeri menjelaskan bahwa mitigasi bencana adalah langkah yang sangat penting dalam penanggulangan bencana, karena ini merupakan upaya yang dilakukan sebelum bencana terjadi, dengan tujuan untuk mengurangi dampak yang mungkin ditimbulkan. Mitigasi mencakup berbagai tindakan untuk menekan atau meminimalkan dampak bencana terhadap masyarakat. Kegiatan pada tahap pra-bencana sangat berkaitan dengan mitigasi bencana, yang merupakan upaya untuk meminimalkan dampak yang mungkin timbul akibat bencana (Wekke, 2021).

2.1.4 Ketahanan Wilayah

Ketahanan wilayah merupakan turunan dari konsep ketahanan nasional yang memiliki pengertian kondisi dinamis dimana suatu wilayah yang mencakup seluruh aspek kehidupan secara terpadu. Ketahanan ini mengandung ketangguhan dan keuletan yang memungkinkan wilayah tersebut mengembangkan kekuatan dalam menghadapi ancaman, hambatan, dan gangguan yang berasal dari dalam maupun luar. Tujuan dari ketahanan wilayah ini adalah untuk menjamin identitas, integritas, kelangsungan hidup bangsa dan negara, serta mendukung pencapaian tujuan pembangunan (Armawi, 2020). Ketahanan wilayah mencakup kemampuan suatu wilayah untuk menghadapi, menanggulangi, dan pulih dari berbagai ancaman, baik yang disebabkan oleh faktor alam maupun tindakan manusia. Konsep ini tidak hanya terbatas pada kemampuan bertahan tetapi juga mencakup daya lentur (*resilience*) dalam menanggapi

perubahan atau guncangan. Ketahanan wilayah menjadi salah satu pondasi penting dalam menjaga stabilitas ekonomi, sosial, dan lingkungan di tengah risiko bencana yang kerap kali tidak dapat diprediksi (Nudin et al., 2011).


Ketahanan wilayah dalam konteks ketahanan bencana melibatkan komponen-komponen seperti kesiapan infrastruktur, kemampuan sistem kesehatan, kapasitas sosial-ekonomi, dan kecepatan pemulihan pasca-bencana. Indonesia sebagai negara dengan risiko bencana tinggi, seperti gempa bumi, tsunami, dan letusan gunung api, mengharuskan pemerintah untuk mengembangkan konsep ketahanan wilayah yang kuat. Kesiapan menghadapi bencana melalui langkah mitigasi yang efisien merupakan aspek utama yang mendukung ketahanan suatu wilayah dalam menghadapi potensi kerugian yang besar. Menurut Buku Putih Pertahanan, bencana alam dikategorikan sebagai ancaman nyata yang berasal dari dalam negeri dan dinilai dapat mengancam kedaulatan negara, keutuhan wilayah, serta keselamatan seluruh bangsa. Indonesia, yang terletak di jalur *Ring of Fire* atau cincin api Pasifik, berada di wilayah dengan aktivitas geologi yang sangat tinggi, di mana jalur pegunungan aktif ini menjadikan Indonesia rentan terhadap gempa bumi tektonik maupun vulkanik. Hal ini membuat Indonesia sering menghadapi risiko bencana alam yang besar, seperti letusan gunung berapi, gempa bumi, dan potensi tsunami, yang semuanya dapat menimbulkan kerusakan infrastruktur, gangguan sosial, hingga korban jiwa. Oleh karena itu, ketahanan wilayah dan kesiapan mitigasi bencana menjadi prioritas nasional yang sangat penting untuk melindungi keselamatan bangsa.

2.1.5 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data yang bersifat sekuensial atau berurutan, seperti deret waktu atau teks. RNN termasuk dalam kategori *deep learning* karena menggunakan struktur jaringan yang terdiri dari beberapa lapisan (*layers*) untuk mempelajari pola kompleks dari data

(Deng, 2024). Salah satu keunggulan RNN adalah kemampuannya untuk menggunakan informasi dari masa lalu sebagai bagian dari proses pembelajarannya, yang memungkinkan model ini untuk mempertimbangkan konteks waktu sebelumnya dalam memprediksi atau mengklasifikasikan data (Zhang et al., 2023).

RNN memiliki struktur yang terdiri dari lapisan *input layer*, *hidden layer*, dan *output layer*. Aliran informasi dalam RNN bergerak satu arah, dimulai dari *input layer* yang memberikan data pada *hidden layer*, dan kemudian informasi dari *hidden layer* sebelumnya disalurkan ke *hidden layer* berikutnya. Output dari *hidden layer* pada satu langkah waktu akan menjadi input untuk langkah berikutnya, sehingga model dapat memproses data secara berurutan dan mempertahankan informasi yang relevan dari langkah-langkah sebelumnya (Wang et al., 2022). Kemampuan ini menjadikan RNN sangat efektif dalam menangani data yang bergantung pada urutan, seperti pada aplikasi prediksi *time series*.



Gambar 2.1 Struktur RNN

Sumber: (Hochreiter & Schmidhuber, 1997)


Berdasarkan Gambar 2.1, RNN memanfaatkan data input yang ada pada waktu saat ini serta informasi dari data sebelumnya. Hubungan antara input-input tersebut sangat penting karena dapat memberikan informasi yang berguna bagi semua *hidden layer*. Oleh karena itu, RNN dapat dianggap memiliki memori yang menyimpan informasi yang diperoleh dari langkah-langkah sebelumnya (Baruah & Organero, 2023).

Secara teori dan berdasarkan desain arsitektur RNN, model ini dirancang untuk menangani ketergantungan jangka panjang (Yahya et al., 2025). Namun, dalam penerapannya, RNN kesulitan untuk mengelola ketergantungan jangka panjang tersebut. Hal ini disebabkan oleh masalah

vanishing gradient, di mana gradien yang digunakan dalam pembaruan parameter menjadi sangat kecil, sehingga model tidak dapat menyimpan informasi dari langkah sebelumnya dengan baik. Untuk mengatasi masalah ini, Hochreiter dan Schmidhuber pada tahun 1997 mengembangkan jenis RNN khusus yang dikenal dengan LSTM (Agarwal et al., 2024).

2.1.6 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf tiruan yang dirancang untuk mengatasi keterbatasan pada *Recurrent Neural Network (RNN)*, terutama masalah *vanishing gradient*, yang menghambat kemampuan model dalam mengingat informasi jangka panjang. LSTM memiliki mekanisme khusus berupa tiga gerbang utama, yaitu *Input Gate*, *Forget Gate*, dan *Output Gate*, yang memungkinkan model untuk memilih informasi mana yang perlu diingat, diperbarui, atau dilupakan (Wang et al., 2020). Selain itu, LSTM memiliki *cell state*, yaitu jalur utama yang mengalirkan informasi sepanjang waktu, membantu model menangkap pola jangka panjang dalam data sekuensial seperti data gempa bumi (Landi et al., 2021).



Gambar 2.2 Struktur LSTM

Sumber: (Hochreiter & Schmidhuber, 1997)

Berdasarkan Gambar 2.2, sel LSTM dilengkapi dengan tiga gerbang utama, yaitu *input gate* (i_t), *forget gate* (f_t), dan *output gate* (o_t), yang masing-masing berfungsi untuk mempertahankan dan memperbarui informasi penting dari data sebelum waktu t . LSTM telah terbukti efektif dalam mengatasi masalah dengan dependensi jangka panjang dan memiliki aplikasi luas dalam berbagai tugas pembelajaran dan prediksi. Proses pembaruan status sel dan parameter ditampilkan sebagai berikut:

1. Forget Gate

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.1)$$

Keterangan:

f_t = *forget gate* pada waktu t

σ = fungsi sigmoid, *output* antara 0 dan 1

W_f = bobot *forget gate*

x_t = *input* pada waktu t

h_{t-1} = *hidden state* dari waktu sebelumnya

b_f = bias *forget gate*

Forget gate berfungsi untuk memutuskan informasi mana dari *cell state* sebelumnya (C_{t-1}) yang perlu dilupakan. Nilai f_t berada dalam rentang 0 hingga 1 menggunakan fungsi sigmoid.

$$\text{sigmoid}(x_i) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$

Nilai 1 berarti menyimpan seluruh informasi, sedangkan nilai 0 berarti melupakan semuanya. Ini penting agar jaringan tidak menyimpan informasi yang tidak relevan terlalu lama.

2. Input Gate

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2.3)$$

Keterangan:

i_t = *input gate* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Input gate mengontrol seberapa besar informasi baru dari input saat ini x_t yang akan dimasukkan ke dalam memori. Bersama dengan $\tilde{C}_t$, gate ini menentukan perubahan terhadap *cell state*.

3. Cell Candidate

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2.4)$$

Keterangan:

$\tilde{C}_t$ = *cell candidate* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Kandidat *cell state* baru dibuat menggunakan fungsi aktivasi *tanh* yang menghasilkan nilai antara -1 dan 1.

$$\tanh(x) = 2\sigma 2x - 1 \quad (2.5)$$

Ini merepresentasikan informasi baru yang bisa ditambahkan ke memori internal, tapi belum tentu seluruhnya akan digunakan (karena akan difilter oleh i_t).

4. Update Cell State

$$C_t = i_t * \tilde{C}_t + f_t * C_{t-1} \quad (2.6)$$

Keterangan:

C_t = *update cell state* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Ini adalah inti dari mekanisme memori LSTM. *Cell state* C_t diperbarui dengan dua bagian: informasi lama yang tetap disimpan (dikalikan dengan f_t), dan informasi baru yang ditambahkan (dikalikan dengan i_t). Kombinasi ini memastikan bahwa LSTM dapat menyimpan informasi penting dalam jangka waktu panjang sambil memperbarui dengan data terbaru.

5. Output Gate

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.7)$$

Keterangan:

o_t = *output gate* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Output gate menentukan bagian dari *cell state* saat ini (C_t) yang akan digunakan sebagai *hidden state* h_t (yang juga menjadi output LSTM pada waktu t). *Gate* ini memungkinkan kontrol seberapa besar informasi internal yang akan dijadikan sebagai *output*.

6. Hidden State Output

$$h_t = o_t * \tanh(C_t) \quad (2.8)$$

Keterangan:

i_t = *input gate* pada waktu t


Komponen lainnya serupa dengan sebelumnya

Hidden state dihasilkan dari *cell state* yang telah diaktifkan melalui fungsi *tanh*, kemudian difilter oleh *output gate* o_t . *Output* ini digunakan untuk prediksi atau diproses lebih lanjut pada waktu berikutnya.

Keunggulan LSTM terletak pada kemampuannya untuk mengolah data *time series*, mengingat pola jangka panjang, dan menangani hubungan non-linear dalam data. Dalam konteks prediksi gempa bumi, kemampuan ini sangat penting karena gempa sering kali memiliki pola tersembunyi yang kompleks dan memerlukan analisis jangka Panjang (Bhandarkar et al., 2019). Fleksibilitas LSTM juga memungkinkan penggunaan model dalam berbagai bentuk, seperti ConvLSTM untuk memproses data spasial-temporal, menjadikannya metode yang efektif untuk mendukung mitigasi dan kesiapsiagaan bencana.

2.1.7 Convolutional Long Short-Term Memory (ConvLSTM)

Convolutional LSTM (ConvLSTM) adalah pengembangan dari arsitektur LSTM yang menggabungkan kemampuan *Long Short-Term Memory* dalam menangani data sekuensial dengan kekuatan dari *Convolutional Neural Network* (CNN) dalam menangani data spasial, seperti gambar atau peta (Altayeva et al., 2023). ConvLSTM dirancang untuk menangani data dengan dimensi spasial-temporal, yaitu data yang tidak hanya berubah terhadap waktu tetapi juga memiliki struktur spasial seperti latitude-longitude, grid seismik, atau citra satelit.



Gambar 2.3 Struktur ConvLSTM

Sumber: (Kumar et al., 2020)

Berdasarkan Gambar 2.3, perbedaan utama ConvLSTM dibandingkan LSTM biasa terletak pada operasi matematis yang digunakan. Jika LSTM menggunakan operasi matriks biasa, ConvLSTM menggunakan konvolusi 2D dalam semua gate. Dengan demikian, ConvLSTM menggunakan tensor 3D sebagai input, output, dan state, yang mencakup waktu dan ruang (Huang et al., 2023). Hal ini memungkinkan ConvLSTM untuk mempertahankan informasi spasial pada data input dan cocok digunakan untuk memodelkan data dengan ketergantungan spasial dan temporal secara bersamaan. Proses pembaruan status sel dan parameter ditampilkan sebagai berikut:

1. *Input Gate*

$$i_t = \sigma(W_{xt} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \quad (2.9)$$

Keterangan:

i_t = *input gate* pada waktu t

σ = fungsi sigmoid, *output* antara 0 dan 1

X_t = *input* pada waktu t

H_{t-1} = *hidden state* dari waktu sebelumnya

C_{t-1} = *cell state* sebelumnya

W = kernel konvolusi

b_i = bias *input gate*

Input gate di ConvLSTM menghitung kontribusi data baru yang akan masuk ke dalam *cell state*. Perbedaan utama di sini adalah penggunaan operasi konvolusi $*$, bukan perkalian matriks, karena input X_t dan hidden state H_{t-1} berbentuk gambar atau peta (tensor 3D).

2. *Forget Gate*

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \quad (2.10)$$

Keterangan:

i_t = *forget gate* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Forget gate berfungsi seperti pada LSTM, namun mempertimbangkan juga lokasi spasial dalam input. *Gate* ini menghapus informasi lama dari cell

state berdasarkan hubungan spasial dari data input dan hidden state sebelumnya.*state*.

3. Update Cell State

$$c_t = f_t \circ C_{t-1} + i_t \circ \tanh (W_{xc}X_t + W_{hc}h_{t-1} + b_c) \quad (2.11)$$

Keterangan:

c_t = *cell state* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Cell state diperbarui seperti pada LSTM, namun semua operasi mempertahankan struktur spasial.

4. Output Gate

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_{t-1} + b_o) \quad (2.12)$$

Keterangan:

o_t = *output gate* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Output gate menghitung bagian dari cell state yang akan digunakan sebagai hidden state baru H_t . Semua bobot di sini adalah kernel konvolusi 2D.

5. Hidden State

$$h_t = o_t * \tanh (C_t) \quad (2.13)$$

Keterangan:

h_t = *hidden state* pada waktu t

Komponen lainnya serupa dengan sebelumnya

Hidden state dihasilkan dari cell state saat ini yang diaktifkan, dikalikan dengan *output gate* dan digunakan untuk prediksi atau diproses lebih lanjut pada waktu berikutnya.

Setiap gate pada ConvLSTM yaitu *forget gate*, *input gate*, *candidate cell*, *output gate*, dan *hidden state* bekerja sama untuk menyaring dan mempertahankan informasi penting dari input spasial yang diberikan. Dengan struktur ini, ConvLSTM dapat belajar bagaimana suatu pola berkembang seiring waktu dan ruang, sehingga menghasilkan prediksi yang lebih akurat pada data yang memiliki dimensi spasial seperti peta atau citra.

2.1.8 Matriks Evaluasi

Matriks evaluasi adalah alat yang digunakan untuk mengukur kinerja model, terutama dalam tugas-tugas prediksi atau klasifikasi, dengan membandingkan hasil yang diprediksi oleh model terhadap nilai yang sebenarnya. Dalam konteks regresi, matriks evaluasi digunakan untuk menilai seberapa dekat hasil prediksi model dengan data aktual (Kennard et al., 2024). Beberapa metrik yang umum digunakan untuk evaluasi model regresi adalah *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *R-squared* yang masing-masing memiliki cara yang berbeda dalam mengukur kesalahan.

1. *Root Mean Squared Error* (RMSE)

Root Mean Squared Error (RMSE) menghitung akar kuadrat dari rata-rata kuadrat selisih antara nilai yang diprediksi dan nilai aktual. RMSE lebih sensitif terhadap kesalahan besar karena kesalahan dikuadratkan sebelum dirata-ratakan (Chicco et al., 2021). Oleh karena itu, RMSE memberi bobot lebih pada kesalahan yang lebih besar, yang menjadikannya lebih cocok digunakan ketika kesalahan besar lebih penting untuk dihindari. Berikut persamaannya:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.14)$$

Keterangan:

y_i = Nilai aktual

$\hat{y}_i$ = Nilai prediksi

n = Jumlah total data

2. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error (MAPE) mengukur kesalahan dalam bentuk persentase dengan membandingkan selisih antara nilai yang diprediksi dan nilai aktual terhadap nilai aktual (Chicco et al., 2021). Nilai MAPE dianggap baik dalam suatu peramalan apabila menghasilkan angka yang rendah atau persentasenya mendekati nol. Berikut persamaannya:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2.15)$$

Keterangan:

y_i = Nilai aktual

$\hat{y}_i$ = Nilai prediksi

n = Jumlah total data

MAPE memiliki rentang nilai yang dapat digunakan sebagai acuan untuk menentukan apakah hasil peramalan termasuk kategori baik atau tidak. MAPE sangat berguna ketika ukuran variabel peramalan menjadi faktor penting dalam menilai akurasi peramalan tersebut. Selain itu, MAPE dilengkapi dengan tabel pengelompokan yang jelas untuk presentase hasil yang diperoleh seperti yang terlihat pada Tabel 2.1, sehingga memudahkan dalam menyimpulkan kategori peramalan tersebut (Kuo et al., 2018).

Tabel 2.1 Kategori Range Nilai MAPE

Range MAPE	Kategori
<10%	Kemampuan model prediksi sangat baik
10-20%	Kemampuan model prediksi baik
20-50%	Kemampuan model prediksi layak
>50%	Kemampuan model prediksi buruk

Sumber: (Kuo et al., 2018)

3. *R-squared* (R^2)

R-squared, juga dikenal sebagai koefisien determinasi, adalah ukuran statistik yang digunakan untuk menilai seberapa baik model regresi linear dalam menjelaskan variabilitas data yang diamati. Nilai R^2 memberikan gambaran seberapa besar bagian dari variabilitas data yang dapat dijelaskan oleh model prediksi (Chicco et al., 2021). Secara matematis, R^2 dihitung dengan menggunakan persamaan berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.16)$$

Keterangan:


y_i = Nilai aktual

$\hat{y}_i$ = Nilai prediksi

$\bar{y}_i$ = Rata-rata nilai aktual

n = Jumlah total data

Nilai *R-squared* digunakan untuk mengukur sejauh mana model dapat menjelaskan variasi dalam data. Semakin mendekati nilai R^2 1, semakin baik kemampuan model dalam menggambarkan hubungan antara variabel independen dan dependen, yang menunjukkan akurasi prediksi yang tinggi (Chicco et al., 2021).



2.2 Hasil Penelitian Terdahulu

Berdasarkan penelitian yang akan dilakukan, diperlukan pembandingan sekaligus bahan referensi dengan mencantumkan hasil penelitian terdahulu yang serupa sebagaimana pada Tabel 2.2 berikut:

Tabel 2.2 Perbandingan Hasil Penelitian Terdahulu

No.	Penulis (Tahun)	Judul	Metode	Hasil
1.	Muhammad Aji Permana & M. Faisal (2023)	Uji Performa Prediksi Gempa Bumi di Jawa Timur dengan Artificial Neural Network	Artificial Neural Network (ANN)	Hasil penelitian menunjukkan bahwa model <i>Artificial Neural Network</i> (ANN) mampu memprediksi frekuensi jumlah kejadian gempa di Jawa Timur, dengan nilai error 0.1958 berdasarkan <i>Sum Square Error</i> (SSE).
2.	Zgongchang Zhang & Yubing Wang (2023)	A Spatio Temporal Model for Global Earthquake Prediction Based on Convolutional LSTM	Convolutional LSTM	Hasil penelitian menunjukkan bahwa model ConvLSTM lebih baik dalam memetakan prediksi spasial gempa bumi dibandingkan metode tradisional, dengan <i>precision</i> 64.54%, <i>recall</i> 51.83%, dan akurasi 99.17% pada dataset M4_2.

3.	Maher Ali Rusho, Reyhan Azizova, Dmytro Mykhalevskiy, Maksym Karyonov & Heyran Hasanova (2024)	Advanced Earthquake Prediction: Unifying Networks, Algorithms, and Attention-Driven LSTM Modelling	Long Sort-Term Memory (LSTM)	Penelitian ini menunjukkan bahwa model LSTM baik dalam mendeteksi pola kejadian seismik dibandingkan metode tradisional, mendukung pengembangan sistem peringatan dini gempa yang lebih andal untuk mitigasi bencana.
----	--	---	---------------------------------	---


Sumber: diolah oleh peneliti

Berbagai penelitian sebelumnya telah mengembangkan model prediksi gempa bumi dengan pendekatan yang beragam, namun masih memiliki keterbatasan dalam mengintegrasikan dimensi spasial dan temporal secara menyeluruh. Permana dan Faisal (2023) menggunakan *Artificial Neural Network* (ANN) untuk memprediksi frekuensi kejadian gempa di Jawa Timur dan memperoleh nilai error sebesar 0.1958 berdasarkan *Sum Square Error* (SSE). Meskipun menunjukkan hasil yang cukup baik dalam mengenali pola frekuensi, pendekatan ini belum mampu memproses informasi spasial seperti lokasi episenter atau kedalaman gempa secara simultan. Sementara itu, Zhang dan Wang (2023) mengusulkan model *Convolutional LSTM* (ConvLSTM) untuk prediksi gempa global dan mencatat *precision* sebesar 64.54%, *recall* 51.83%, serta akurasi 99.17% pada dataset M4_2. Model ini terbukti efektif dalam menangani data spasial, namun hanya berfokus pada lokasi geografis tanpa mempertimbangkan aspek penting lainnya seperti kedalaman atau frekuensi gempa. Di sisi lain, Rusho et al. (2024) menerapkan model *Long Short-Term Memory* (LSTM) untuk mendeteksi pola seismik dan

mengembangkan sistem peringatan dini yang lebih akurat. Namun, hasil prediksi yang dihasilkan belum disajikan dalam bentuk visualisasi spasial yang aplikatif untuk kepentingan mitigasi bencana secara langsung.

Berdasarkan kajian tersebut, masih terdapat gap penelitian yang perlu dijawab, yaitu belum adanya model yang secara khusus mengintegrasikan prediksi spasial dan temporal dalam satu sistem prediktif yang lengkap, terutama pada skala regional seperti Provinsi Jawa Barat yang memiliki kerentanan seismik tinggi. Penelitian ini bertujuan untuk menjawab kekosongan tersebut dengan menerapkan pendekatan gabungan antara ConvLSTM dan LSTM. Model ConvLSTM digunakan untuk memprediksi lokasi episenter gempa (longitude dan latitude), sedangkan model LSTM difokuskan untuk memprediksi kedalaman dan magnitudo gempa berdasarkan data historis. Integrasi kedua model ini diharapkan mampu menangkap dinamika spasial-temporal secara simultan. Selain itu, penelitian ini juga menghasilkan visualisasi spasial dari hasil prediksi dalam bentuk peta sebaran, yang dapat dimanfaatkan untuk mendukung sistem mitigasi, peringatan dini, meningkatkan kesadaran masyarakat, serta memperkuat ketahanan wilayah terhadap risiko gempa bumi di Provinsi Jawa Barat.

2.3 Kerangka Berpikir



Gambar 2.4 Kerangka Berpikir

Sumber: diolah oleh peneliti

Berdasarkan Gambar 2.4, pada penelitian ini akan dilakukan pemetaan prediksi kejadian gempa bumi di Jawa Barat dengan menggunakan data historis dari tahun 1973 hingga 2024. Proses dimulai dengan pengumpulan dataset yang mencakup data episenter, magnitudo, dan kedalaman gempa. Data ini kemudian digunakan sebagai dasar dalam analisis dan pembuatan prediksi. Untuk memprediksi lokasi gempa, digunakan model ConvLSTM, yang mampu menangani data spasial dan temporal secara bersamaan. Ini penting karena informasi tentang lokasi gempa sangat dipengaruhi oleh faktor ruang dan waktu. Sementara itu, untuk memprediksi magnitudo dan kedalaman gempa, digunakan model Long Short-Term Memory (LSTM), yang dirancang untuk menangani data urutan waktu dan mengingat informasi jangka panjang dengan lebih efektif.

Setelah model ConvLSTM dan LSTM diterapkan pada data episenter, magnitudo, dan kedalaman, langkah selanjutnya adalah evaluasi model. Di tahap ini, hasil prediksi dari model dibandingkan dengan data aktual untuk menilai seberapa akurat model tersebut. Evaluasi dilakukan dengan menggunakan metrik seperti RMSE, MAPE, dan R^2 yang akan mengukur seberapa dekat prediksi model dengan nilai yang sebenarnya. Tahap terakhir adalah pemetaan prediksi gempa bumi di Jawa Barat berdasarkan hasil evaluasi model. Peta ini akan menunjukkan wilayah-wilayah yang berpotensi terkena dampak gempa, berdasarkan prediksi mengenai magnitudo, kedalaman, dan lokasi episenter yang dapat digunakan untuk meningkatkan kesiapsiagaan dan mitigasi bencana di Jawa Barat.