


BAB 3

METODE PENELITIAN

Metode penelitian pada studi ini terdiri dari dua bagian utama. Bagian pertama adalah pengembangan *big data* hasil analisis dinamika struktur. Setelah sistem *big data* terbangun, bagian selanjutnya adalah pengembangan sistem AI. Diagram alir penelitian disajikan pada Gambar 3.1. Penjelasan detail mengenai langkah-langkah penelitian dijelaskan pada bagian berikutnya.



Gambar 3.1. Diagram alir penelitian

3.1 Pengembangan *Big Data* Nilai SIS

Tahap pertama dalam penelitian ini adalah pengembangan *big data* nilai SIS. Tahap ini terdiri dari pengumpulan data gempa dan tanah, analisis dinamika struktur, perhitungan nilai SIS, dan kalibrasi *dataset* nilai SIS.


3.2 Pengumpulan Data Gempa dan Tanah

Data gempa dalam penelitian ini berjumlah 2.075 kejadian gempa dengan jarak episentrum terjauh 500 km pada rentang tahun 1996-2022, yang direkam oleh 550 titik observasi (stasiun). Data ini diunduh dari sumber terbuka (*open source*) dengan alamat laman <https://www.kyoshin.bosai.go.jp/>, yaitu situs basis data rekaman gempa yang mencakup seluruh wilayah Jepang (National Research Institute for Earth Science and Disaster Resilience, 2019). Laman ini dikembangkan oleh National Research Institute for Earth Science and Disaster Resilience (NIED) dengan terminologi K-NET (Kyoshin Network), yaitu jaringan seismograf gerakan tanah kuat (*strong-motion*) yang terdiri dari 1.047 stasiun observasi dan terdistribusi setiap radius 20 km meliputi seluruh wilayah Jepang (National Research Institute for Earth Science and Disaster Resilience, 2012). Contoh laman sumber data gempa dapat dilihat pada Gambar 3.2.


Pada penelitian ini, data gempa yang diolah adalah magnitudo gempa, jarak episentrum ke stasiun gempa, kedalaman sumber gempa, dan riwayat waktu percepatan gerakan tanah (*ground motion acceleration*). Dari keempat jenis data tersebut, data riwayat waktu digunakan sebagai masukan (*input*) analisis dinamika struktur untuk mengevaluasi respons percepatan tiap lantai hingga menghasilkan nilai SIS. Sementara itu, data magnitudo gempa, jarak episentrum ke stasiun gempa, dan kedalaman sumber gempa digunakan pada tahap pelatihan, uji validasi, dan prediksi SIS dalam sistem kecerdasan buatan.

Data tanah yang digunakan pada penelitian ini adalah data uji bor tanah di bawah stasiun gempa sesuai data gempa yang telah dikumpulkan. Contoh data tanah disajikan pada Gambar 3.3. Data tanah yang diolah meliputi kecepatan rambat gelombang geser primer (V_p) dan sekunder (V_s) pada tanah, serta berat jenis tanah (ρ_s). Rasio Poisson (ν) diperoleh dari persamaan korelasi dengan rasio V_p/V_s (Poulos, 2022). Parameter-parameter ini menjadi masukan dalam menghitung kekakuan dan redaman tanah tahap analisis dinamika struktur, seperti dijabarkan pada sub-bab 2.2.4.4 (hal. 24). Sementara

itu, data V_s menjadi salah satu parameter dalam tahap pelatihan hingga prediksi dari sistem kecerdasan buatan.



Gambar 3.2. Contoh laman pengambilan data gempa (National Research Institute for Earth Science and Disaster Resilience, 2020)



Gambar 3.3. Contoh data tanah yang diambil dari situs K-NET (National Research Institute for Earth Science and Disaster Resilience, 2019)

3.2.1 Penentuan Parameter-parameter Dasar

a. Parameter-parameter Dasar untuk Variasi Material

Parameter-parameter dasar material bangunan, baik beton bertulang, baja struktural, dan kayu, ditentukan berdasarkan kondisi praktis di lapangan dan referensi pendukung. Untuk variasi material beton, mutu $f'_c = 25 \text{ MPa}$ atau modulus elastisitas $E_c = 23.500 \text{ MPa}$ digunakan sebagai parameter dasar model bangunan beton bertulang, dengan massa jenis $\rho_c = 2,4 \text{ t/m}^3$. Parameter dasar untuk variasi material baja ditentukan dengan spesifikasi umum material baja, yaitu $E_s = 200.000 \text{ MPa}$ dan $\rho_{st} = 7,85 \text{ t/m}^3$. Sementara itu, penentuan parameter dasar variasi material kayu mengacu pada penggunaan praktis di lapangan, yaitu menggunakan kayu bangkirai dengan kuat mutu D40 (Sarum Hardwood Structures LTD, 2017). Kayu ini memiliki modulus elastisitas $E_t = 11.000 \text{ MPa}$ dan massa jenis $\rho_t = 0,59 \text{ t/m}^3$. Tabel 3.1 menyajikan parameter-parameter dasar dari seluruh variasi material yang digunakan dalam penelitian ini. Parameter-parameter ini akan menentukan matriks massa $[M]$ dan kekakuan $[K]$ dalam tahap pemodelan struktur.

Tabel 3.1. Parameter-parameter dasar berbagai variasi material


No.	Parameter	Variasi Material		
		Beton	Baja	Kayu
1	Modulus elastisitas (MPa)	23.500	200.000	11.000
2	Massa jenis (t/m^3)	2,40	7,85	0,59
3	<i>Damping ratio</i>	5%	2%	1%

b. Parameter untuk Variasi Jumlah Lantai

Variasi jumlah lantai ditentukan dengan mempertimbangkan penggolongan jenis bangunan menurut jumlah lantai. Mengacu pada PP No. 36 tahun 2005 tentang Peraturan Bangunan Gedung, bangunan diklasifikasikan menjadi: bangunan rendah (jumlah lantai bangunan gedung sampai dengan 4 lantai), bangunan sedang (jumlah lantai bangunan gedung 5-8 lantai), dan bangunan tinggi (jumlah lantai bangunan lebih dari 8 lantai). Pada penelitian ini, parameter jumlah lantai ditetapkan sebagai berikut: satu (1) hingga tiga (3) lantai untuk bangunan rendah, empat (4) hingga delapan (8) lantai untuk bangunan menengah, dan sembilan (9) lantai untuk bangunan tinggi. Dengan demikian, variasi model berdasarkan jumlah lantai pada penelitian ini telah mencakup seluruh klasifikasi bangunan menurut jumlah lantai.

3.2.2 Pemodelan *Lumped-Mass* untuk Struktur Bangunan dan Interaksi Tanah-Struktur (ITS)

Pemodelan *lumped-mass* dipilih sebagai idealisasi struktur pada penelitian ini karena dapat menghasilkan luaran berupa perilaku-perilaku dinamika struktur dengan lebih cepat dibandingkan dengan pemodelan struktur *beam element*. Pemodelan ini diawali dengan proses desain elemen-elemen struktur bangunan atas dengan model 3D untuk memastikan bahwa bangunan memenuhi persyaratan bangunan tahan gempa. Bangunan difungsikan sebagai hunian (apartemen/rumah susun) dengan kategori risiko II dan faktor keutamaan 1,00. Denah bangunan direncanakan simetris untuk menghindari adanya ketidakberaturan struktur, sebagaimana diilustrasikan pada Gambar 3.4. Pada ilustrasi ini, konfigurasi struktur model 6 lantai merepresentasikan ilustrasi model keseluruhan lantai.



Gambar 3.4. Ilustrasi model 3D

Dari hasil desain model 3D, diperoleh data massa tiap lantai dan periode alami struktur. Selain itu, dengan analisis modal, bentuk ragam (*mode shape*) dan frekuensi

sirkular juga dapat diperoleh. Kedua parameter ini digunakan untuk mengevaluasi kekakuan struktur seluruh lantai pada model berdasarkan metode *fundamental lateral translational mode-shape method* (metode bentuk ragam translasional lateral dasar), seperti diuraikan pada sub-bab 2.2.4.2. Dengan demikian, keseluruhan tahap ini menghasilkan matriks massa $[M]$ dan kekakuan $[K]$ dari struktur atas model dalam bentuk *lumped-mass*, yang selanjutnya diverifikasi terhadap model 3D dengan membandingkan nilai periode getar strukturnya. Pada Gambar 3.5, data struktur atas bangunan meliputi massa ($m_{i \sim n}$), kekakuan ($k_{i \sim n}$), dan redaman ($c_{i \sim n}$), di mana indeks i menunjukkan tingkat lantai dan n adalah jumlah lantai.


Pada bagian struktur bawah, massa fondasi (m_b) ditentukan berdasarkan rasionya terhadap massa total struktur atas (M_{up}), mengacu pada penelitian Ahmadi et al. (2015). Untuk bangunan 1-3 lantai, masa fondasi, $m_b = 0,25M_{up}$, sedangkan untuk bangunan 4-6 lantai, $m_b = 0,3M_{up}$, serta untuk bangunan 7-9 lantai, $m_b = 0,35M_{up}$. Sementara itu, nilai kekakuan dan redaman tanah (k_s dan c_s) dihitung berdasarkan Persamaan 2.12 dan 2.13 (hal. 24), dengan nilai-nilai V_s , ρ_s , dan ν diambil dari data tanah di setiap stasiun seismik. Dengan demikian, pada penelitian ini, bangunan dimodelkan terletak di posisi stasiun-stasiun seismik yang datanya telah dikumpulkan. Ilustrasi model *lumped-mass* Interaksi tanah-struktur (ITS) ditunjukkan pada Gambar 3.5. Dari gambar, tampak bahwa derajat kebebasan struktur total untuk tiap tipe bangunan adalah sebanyak jumlah lantai bangunan ditambah satu derajat kebebasan struktur bawah.

Dari penentuan properti massa dan kekakuan struktur bawah, matriks massa dan kekakuan ITS dapat dirumuskan sebagai berikut (Persamaan 3.1 dan 3.2):

$$[M] = \begin{bmatrix} M_{n \times n} & 0 \\ 0 & m_b \end{bmatrix} \quad (3.1)$$

$$[K] = \begin{bmatrix} K_{n \times n}^1 & K_{n \times 1}^2 \\ [K_{n \times 1}^2]^T & k_1 + k_s \end{bmatrix} \quad (3.2)$$

dengan $M_{n \times n}$ dan $K_{n \times n}^1$ adalah matriks massa dan kekakuan struktur atas diurutkan dari lantai tertinggi hingga lantai 1, $K_{n \times 1}^2 = \{0, 0, \dots, -k_1\}^T$, dan k_1 adalah kekakuan lantai 1.



Gambar 3.5. Model *lumped-mass* ITS

Matriks redaman ITS dibangun dengan menggabungkan matriks redaman struktur atas dan bawah. Matriks redaman struktur atas dievaluasi dengan metode *Rayleigh*, seperti diuraikan dalam sub-bab 2.2.4.3 (hal. 24), dengan rasio redaman untuk material struktur beton, baja, dan kayu berturut-turut adalah 5%, 2%, dan 1%. Matriks redaman ini kemudian digabungkan dengan matriks redaman struktur bawah sehingga terbentuk matriks redaman ITS sebagai berikut (Persamaan 3.3), dengan keterangan notasi selaras dengan keterangan matriks $[K]$ di atas (Persamaan 3.2).


$$[C] = \begin{bmatrix} C_{n \times n}^1 & C_{n \times 1}^2 \\ [C_{n \times 1}^2]^T & c_1 + c_s \end{bmatrix} \quad (3.3)$$

Pemodelan ITS dan analisis lanjutan pada penelitian ini menggunakan bantuan program MATLAB. Terdapat 3 skrip kode atau program untuk keseluruhan proses ini, yaitu untuk model bangunan beton, baja, dan kayu. Pembagian tersebut ditujukan untuk efektivitas pengerjaan yaitu adanya kemungkinan eksekusi program secara paralel untuk ketiga variasi material. Setiap program tersebut didukung oleh subprogram untuk membangun model *lumped-mass* (Lampiran 1) dan subprogram untuk menghitung nilai SIS tiap lantai.

3.2.3 Analisis Dinamika Struktur

Analisis dinamika struktur dilakukan terhadap model *lumped-mass* untuk berbagai variasi kondisi bangunan. Terdapat masing-masing 9 model bangunan untuk material beton bertulang dan baja, yaitu bangunan 1 hingga 9 lantai, sedangkan untuk material kayu hanya dibatasi model bangunan 1 hingga 3 lantai. Analisis dinamika struktur dilakukan untuk memperoleh respons percepatan di tiap lantai model termasuk pada lantai/tanah dasar.

Matriks $[M]$, $[K]$, dan $[C]$ model *lumped-mass* ITS dengan berbagai variasi material dan jumlah lantai dikenai beban dinamis berupa riwayat waktu (*time history*) tanah dasar dari seluruh data gempa yang telah dikumpulkan. Beban dinamis ini terdiri dari 2 arah yaitu barat-timur (BT) dan utara-selatan (US). Persamaan gerak pada Persamaan 2.17 diselesaikan dengan integrasi numerik metode Beta-Newmark (sub-bab 2.2.4.5) untuk memperoleh solusi berupa respons percepatan tiap lantai (Gambar 3.6). Proses ini dijalankan dengan bantuan program MATLAB secara iteratif hingga menghasilkan respons percepatan pada tiap lantai untuk seluruh kombinasi variasi data.



Gambar 3.6. Ilustrasi analisis dinamika struktur pada model *lumped-mass*

3.2.4 Hitungan dan Pengembangan *Big Data* Nilai SIS

Hasil dari analisis dinamik pada tahap sebelumnya berupa data riwayat waktu respons percepatan yang terjadi pada tiap lantai akibat beban gempa. Dari hasil-hasil tersebut,

nilai SIS dievaluasi untuk memperoleh berbagai nilai intensitas guncangan pada tiap lantai bangunan untuk semua kombinasi variasi kondisi. Perhitungan nilai SIS dilakukan untuk setiap lantai bangunan sesuai langkah-langkah pada Gambar 2.2 (hal. 18), dengan mempertimbangkan 2 arah respons percepatan.


Seluruh hasil analisis dinamika struktur dan perhitungan nilai SIS dikumpulkan dalam satu data raya (*big data*), yang mencakup seluruh parameter seperti ditunjukkan pada Gambar 3.7. Data gempa diilustrasikan dengan garis rambatan gelombang gempa dengan kekuatan gempa (magnitudo) tertentu yang merambat ke suatu bangunan dengan jarak episentrum dan kedalaman hiposentrum tertentu dari pusat gempa di titik *G*. Parameter-parameter lain seperti karakter tanah, jenis material bangunan, dan variasi jumlah lantai, telah dijelaskan pada bagian sebelumnya. Sebagai tambahan, parameter percepatan puncak dasar atau *peak ground acceleration* (PGA) dan periode getar alami struktur juga dipertimbangkan dalam data raya. Intensitas guncangan tiap lantai (SIS_i) menjadi data luaran (target) dalam data raya. Data raya ini akan menjadi masukan *dataset* untuk tahap selanjutnya, yaitu pengembangan model AI.

3.2.5 Verifikasi *Dataset* Nilai SIS

Verifikasi nilai SIS dilakukan untuk memastikan ketepatan hasil hitungan SIS yang telah dikumpulkan dalam *big data* sebelumnya. Data intensitas guncangan dari NIED (National Research Institute for Earth Science and Disaster Resilience, 2020) digunakan sebagai data pembandingan untuk validasi nilai SIS. Sejumlah 43.575 data nilai SIS di lantai dasar dari seluruh hasil hitungan SIS dibandingkan dengan nilai SIS yang berasal dari data NIED. Proses pengembangan model AI dapat dilakukan jika hasil validasi menunjukkan tingkat korelasi yang tinggi antara nilai SIS hasil hitungan dengan nilai SIS dari data pembandingan.

3.3 Pengembangan Sistem AI

Tahap kedua dalam penelitian ini adalah pengembangan sistem AI. Tahap ini terdiri dari identifikasi *dataset*, pelatihan data, uji validasi, dan prediksi model AI. Pengembangan AI pada penelitian ini bertujuan untuk menemukan model AI yang paling optimal dengan memanfaatkan fasilitas (*toolbox*) *Deep Learning* dan *Statistics and Machine Learning* pada perangkat lunak MATLAB. Kriteria optimal dalam penelitian ini mengacu pada hasil uji validasi model AI.



Gambar 3.7. Ilustrasi variasi parameter dalam *big data*

3.3.1 Identifikasi Dataset

Dataset adalah kumpulan parameter-parameter yang dipertimbangkan dalam melakukan proses *learning* (pembelajaran) atau *training* (pelatihan) pada sistem AI. Terdapat dua bagian dalam *dataset* pada penelitian ini, yaitu parameter-parameter *input* dan parameter *output*. Parameter input terdiri dari parameter jarak lokasi ke episentrum, kedalaman hiposentrum, magnitudo gempa, PGA, material bangunan, karakter tanah yang diwakili oleh V_s , jumlah lantai, nomor lantai, dan periode alami struktur. Pada Gambar 3.7, parameter *input* ditunjukkan dengan obyek-obyek berwarna merah. Sementara itu,

dataset output adalah nilai-nilai SIS pada tiap lantai bangunan, dideskripsikan dengan obyek-obyek berwarna biru pada gambar yang sama.

3.3.2 Normalisasi Data

Dataset yang sudah diidentifikasi perlu dinormalisasi sebelum digunakan sebagai *input* baik dalam proses pelatihan maupun uji validasi. Normalisasi data adalah teknik penskalaan data *input* ke dalam rentang nilai tertentu dengan tujuan untuk mengoptimasi proses pengolahan data dalam model AI agar lebih stabil dan efisien. Pada studi ini, digunakan teknik normalisasi data *min-max normalization* yang diuraikan dalam Persamaan 3.4. Notasi x , x_{min} , dan x_{max} adalah data awal (belum dinormalisasi), data terkecil, dan data terbesar dari suatu rangkaian parameter data, sedangkan x_{norm} adalah nilai hasil normalisasi data.

$$x_{norm} = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (3.4)$$

3.3.3 Pemilahan Data

Pemilahan data bertujuan untuk mengelompokkan *dataset* ke dalam dua kategori, yaitu data pelatihan (*training data*) dan data uji validasi. Pada umumnya, jumlah data pelatihan adalah 90% dari total jumlah data, sedangkan data uji validasi 10% dari total tersebut, seperti pada penelitian Gan (2023) dan Díaz et al. (2022). Sementara itu, data untuk prediksi disiapkan secara khusus di luar data pelatihan dan uji validasi. Pemilahan dilakukan secara acak untuk memastikan kerataan sebaran data. Pada studi ini, dari total 242.775 jumlah data, sejumlah 218.497 data acak digunakan sebagai data pelatihan, sedangkan sisanya sejumlah 24.035 digunakan sebagai data uji validasi, serta 243 sebagai data untuk prediksi.


3.3.4 Pelatihan Data dalam Model AI

Pada bagian ini, tiga alternatif model AI dikembangkan dan diobservasi. Ketiga model itu dibedakan oleh metode atau algoritma yang diimplementasikan, yaitu *Convolutional Neural Network* (CNN), *Neural Network* (NN), dan *Gradient Boosting* (GB). Performa dari ketiga model tersebut akan dibandingkan pada tahap berikutnya, yaitu uji validasi.

3.3.4.1 Model CNN

Model CNN dikembangkan dengan *input dataset* yang telah tersedia. Sejumlah 218.497 *dataset* akan digunakan sebagai masukan untuk pelatihan data dalam model AI. *Dataset* dalam pemodelan ini kemudian dilatih untuk 30 *epochs* menggunakan *mini-batch*

berukuran 128, mengacu pada penelitian terdahulu yang dilakukan oleh Gan (2023). Penyusunan lapisan-lapisan jaringan CNN pada studi ini juga mengacu pada penelitian tersebut dengan modifikasi pada jenis prediksi yang dilakukan hanya pada nilai SIS dengan teknik regresi, seperti ditunjukkan pada Gambar 3.8.



Gambar 3.8. Arsitektur model CNN

Pelatihan data dilakukan dengan algoritma *backpropagation*, di mana dalam tahap ini nilai bobot (*weights*) lapisan-lapisan DNN dievaluasi dan diperbaharui (*update*) secara iteratif hingga menghasilkan nilai galat (*loss score*) semimumimum mungkin. Teknik optimasi yang digunakan untuk *update* nilai bobot dan galat pada penelitian ini adalah *stochastic gradient descent with momentum* (SGDM).

3.3.4.2 Model NN

Pengembangan model NN memanfaatkan implementasi proses penyetelan hiperparameter otomatis (*auto hyperparameters tuning*) untuk mengoptimasi model. Proses ini diatur sedemikian rupa supaya menghasilkan kombinasi parameter model yang mencapai nilai objektif terbaik (*best*). Nilai objektif yang ditetapkan berkaitan dengan *loss scores*, yaitu $\log(1 + \text{loss})$, sehingga nilai objektif terbaik yang diharapkan adalah nilai terkecil dari seluruh iterasi yang dilakukan. Proses ini diatur sedemikian rupa supaya menghasilkan kombinasi parameter model yang mencapai nilai objektif terbaik (*best*). Nilai objektif yang ditetapkan berkaitan dengan *loss scores*, yaitu $\log(1 + \text{loss})$, sehingga nilai objektif terbaik yang diharapkan adalah nilai terkecil dari seluruh iterasi yang dilakukan. Pada studi ini, iterasi penyetelan hiperparameter otomatis dibatasi sebanyak 30 iterasi. Melalui proses ini, kombinasi terbaik parameter-parameter dalam tiap metode dihasilkan berdasarkan nilai objektif terbaik. Pada model NN, parameter-parameter properti hasil optimasi antara lain jumlah lapisan, jumlah jaringan (*neuron*), dan fungsi aktivasi yang digunakan.

3.3.4.3 Model GB

Seperti pada model NN, model GB juga dikembangkan dengan implementasi *auto hyperparameters tuning*. Nilai objektif dan jumlah iterasi maksimum juga disesuaikan dengan penentuan pada model NN, yaitu $\log(1 + \text{loss})$ dan 30 iterasi. Namun, terdapat perbedaan pada model GB, di mana parameter-parameter properti yang dihasilkan dari optimasi yaitu metode yang digunakan dalam pelatihan, jumlah siklus dan *learning rate*, ukuran daun terkecil (*MinLeafSize*), dan jumlah pemisahan terbesar (*MaxNumSplits*).

3.3.5 Uji Validasi Model AI

Uji validasi terhadap kinerja model AI dilakukan menggunakan sejumlah *dataset* yang telah disiapkan sebelumnya. Dari tahap pelatihan, tiap model AI memiliki algoritma masing-masing untuk melakukan prediksi nilai SIS, berdasarkan parameter-parameter *dataset*. Hasil prediksi ini kemudian dibandingkan dengan hasil hitungan SIS manual (analisis dinamika struktur dengan riwayat waktu), kemudian diolah berdasarkan kriteria uji validasi untuk menilai kinerja tiap model. Kriteria uji validasi yang diobservasi pada penelitian ini adalah *root mean square error* (RMSE), *mean absolute percentage error* (MAPE), dan uji *r-square* (R^2), dengan rumus yang dituliskan pada Persamaan 3.5 hingga 3.7. Pada persamaan-persamaan tersebut, notasi N adalah jumlah data uji validasi, y_i nilai aktual SIS tiap lantai pada data observasi tunggal, $\hat{y}_i$ nilai prediksi SIS, dan $\bar{y}$ rerata nilai aktual SIS. Selain itu, nilai *error* tertinggi dan sebaran data (histogram) nilai *error* juga dipertimbangkan sebagai kriteria. Pada tahap ini, kinerja tiap model akan dibandingkan dan dipilih yang terbaik untuk diimplementasikan selanjutnya dalam tahap prediksi.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (3.5)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (3.6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.7)$$

3.3.6 Prediksi Model AI

Model AI terbaik berdasarkan uji validasi diaplikasikan untuk memprediksi SIS dari *dataset* yang telah disiapkan khusus untuk prediksi. Hasil prediksi SIS pada tahap ini dibandingkan dengan hasil hitungan SIS manual (analisis dinamika struktur dengan riwayat waktu) dari salah satu kasus dalam *dataset* prediksi, dengan mempertimbangkan kategori SIS sesuai tabel JMA.