

FRAMEWORK PENGGUNAAN *KALMAN FILTER* DALAM KONSEP DIGITAL TWIN

Rachmad Irwanto^{1*} Arnoldus Jean Cornelis²

^{1,2}Teknik Sipil, Fakultas Teknik dan Informatika, Universitas 17 Agustus 1945 Jakarta

*Email: rachmad.irwanto@uta45jakarta.ac.id

Abstrak

Rekayasa struktur telah lama mengandalkan penerapan Metode Elemen Hingga (*Finite Element Method/FEM*) untuk mensimulasikan kinerja struktur di bawah berbagai kondisi pembebanan. Namun, model *FEM* tradisional tidak memiliki umpan balik waktu nyata, yang membatasi efektivitasnya dalam pemantauan adaptif dan pemeliharaan prediktif. Makalah ini menyajikan kerangka konseptual untuk mengintegrasikan data *Structural Health Monitoring (SHM)* dengan hasil *FEM* guna menerapkan pendekatan *Digital Twin (DT)* dalam penilaian struktural. Untuk menerapkan *DT*, data *SHM* digunakan sebagai masukan dalam simulasi *FEM*, memungkinkan pembaruan struktur secara waktu nyata. Metode pembaruan berbasis *Kalman filter* diterapkan untuk menyaring data *SHM*, mengurangi derau (*noise*) pengukuran, dan meningkatkan akurasi prediksi. Metodologi ini diilustrasikan menggunakan data fabrikasi, yang menunjukkan bagaimana simulasi numerik dapat memproses input *SHM*, menyelaraskannya dengan perpindahan yang diprediksi oleh *FEM*, serta mendeteksi potensi anomali struktural. Hasil penelitian ini menyoroti bagaimana pembaruan data-driven pada *FEM* dapat meningkatkan pemeliharaan prediktif dan mengurangi ketidakpastian dalam pemantauan struktur. Studi konseptual ini menekankan pentingnya *Digital Twin* dalam rekayasa struktur serta memberikan landasan bagi penelitian lebih lanjut dalam diagnostik struktural berbasis *machine learning*. Pengembangan di masa depan dapat mencakup integrasi sensor waktu nyata, deteksi kerusakan berbasis kecerdasan buatan (*AI*), dan pembaruan model *FEM* secara otomatis guna memungkinkan sistem penilaian struktur yang sepenuhnya adaptif.

Kata kunci: *Digital Twin, FEM, Structural Health Monitoring, Kalman filter*

Abstract

Structural engineering has long relied on *Finite Element Method (FEM)* applications to simulate the performance of structures under various loading conditions. However, traditional *FEM* models lack real-time feedback, limiting their effectiveness in adaptive monitoring and predictive maintenance. This paper presents a conceptual framework for integrating *Structural Health Monitoring (SHM)* data with *FEM* results to enable a *Digital Twin (DT)* approach for structural assessment. To implement *DT*, *SHM* data serves as an input feeder for *FEM* simulations, allowing real-time structural updates. A *Kalman filter*-based updating method is applied to smooth *SHM* data, reducing measurement noise and improving predictive accuracy. The methodology is illustrated using fabricated data, demonstrating how numerical simulations can process *SHM* inputs, align them with *FEM*-predicted displacements, and detect potential structural anomalies. The results highlight how data-driven *FEM* updates can enhance predictive maintenance, reducing uncertainties in structural monitoring. This conceptual study underscores the importance of *Digital Twins* in structural engineering and provides a foundation for future research in machine learning-enhanced structural diagnostics. Future developments could include real-time sensor integration, *AI*-driven damage detection, and automated *FEM* model updating, enabling a fully adaptive structural assessment system.

Keywords: *Digital Twin, FEM, Structural Health Monitoring, Kalman filter*

1. PENDAHULUAN

Rekayasa struktur secara umum menggunakan simulasi Metode Elemen Hingga (*Finite Element Method - FEM*) untuk menilai kinerja bangunan dan infrastruktur dalam berbagai skenario pembebanan. Dengan cara ini, *FEM* memberikan wawasan berharga dalam desain dan penilaian keamanan struktur. Namun, model *FEM* tradisional beroperasi berdasarkan asumsi yang telah ditentukan sebelumnya dan umumnya digunakan dalam fase pra-konstruksi atau validasi desain, sehingga memiliki keterbatasan dalam beradaptasi dengan perubahan kondisi struktur secara waktu

nyata. Sebaliknya, sistem *Structural Health Monitoring* (SHM) menggunakan data sensor di lapangan (misalnya, akselerometer, *strain gauge*, dan *displacement transducer*) untuk secara terus-menerus melacak kinerja aktual suatu struktur. Dengan mengintegrasikan data SHM dengan simulasi FEM, para insinyur dapat menciptakan *Digital Twin* (DT), yaitu representasi virtual dari struktur fisik yang diperbarui secara *real-time*. Integrasi ini meningkatkan efektivitas pemeliharaan prediktif, deteksi dini anomali, serta pengambilan keputusan adaptif dalam menjamin keselamatan struktur.

Sebuah tulisan di tahun 2020 oleh Ye et al. (Ye, Yang, Yang, Huo, & Meng, 2020) menyoroti bagaimana konsep DT diterapkan untuk pemantauan kesehatan struktural secara berkelanjutan, bahkan di luar infrastruktur sipil. Ye et al. mengusulkan kerangka kerja DT untuk melacak usia struktur kedirgantaraan (*aerospace*). Tulisan tersebut menggambarkan pembaruan model secara *real-time* untuk manajemen integritas struktural. Studi kasus ini menunjukkan bahwa DT *real-time* dengan *extended Kalman filter* sudah meningkatkan pemantauan struktural dalam aplikasi berisiko tinggi. Hal ini menekankan pentingnya DT lintas-domain untuk diagnostik struktural dan mendorong pendekatan serupa dalam teknik sipil. Tulisan lain dari Yu et al. (Yu, Li, & Ou, 2022) memperkenalkan bagaimana DT digunakan dalam infrastruktur sipil untuk pemantauan *real-time*. Mereka menggambarkan “metode pemantauan hibrida” yang mensintesis data sensor langsung dengan model elemen hingga sebuah jembatan, sehingga secara efektif menciptakan digital twin untuk jembatan *cable-stayed*. Hal ini mendukung pernyataan tentang nilai integrasi data SHM dengan simulasi FE. Sebagai contoh, saat menjelaskan bahwa DT “menjembatani kesenjangan” antara pengukuran lapangan dan model numerik, studi Yu et al. dapat dikutip sebagai bukti bahwa penggabungan data pemantauan dan model FE membantu merekonstruksi respons yang tidak terukur dan menafsirkan perilaku struktural secara *real-time*.

Meskipun perangkat lunak FEM telah banyak digunakan, keterbatasannya dalam memberikan umpan balik waktu nyata menjadi tantangan utama dalam pemantauan struktur selama fase operasional. Banyak struktur mengalami kondisi pembebanan yang tidak terduga, degradasi material, serta dampak lingkungan yang tidak diperhitungkan oleh model FEM setelah konstruksi selesai. SHM menawarkan solusi dengan menyediakan respons terukur terhadap kondisi tersebut, tetapi data yang diperoleh sering kali mengandung derau (*noise*), tidak lengkap, dan sulit diinterpretasikan dalam konteks teknik yang bermakna.

Konsep *Digital Twin* (DT) hadir sebagai solusi untuk menjembatani kesenjangan ini dengan mengintegrasikan prediksi FEM dengan data SHM secara *real-time*, yang memungkinkan:

- Penilaian struktural secara langsung, tidak hanya mengandalkan simulasi pra-konstruksi.
- Pembaruan model FEM berbasis data, sehingga mengurangi ketidakpastian dalam prediksi kinerja struktur.
- Strategi pemeliharaan prediktif yang memungkinkan deteksi kerusakan sebelum kegagalan terjadi.
- Deteksi anomali menggunakan metode statistik atau kecerdasan buatan (AI).

Namun, data mentah dari SHM sering kali mengandung derau dan ketidakaturan yang menyulitkan integrasi langsung dengan FEM. Oleh karena itu, diperlukan teknik pemrosesan data seperti *Kalman filter* atau metode fusi data lainnya untuk menyaring data SHM dan menyelaraskannya dengan prediksi FEM.

Makalah ini menyajikan sebuah kerangka konseptual sederhana untuk mengintegrasikan data SHM dengan hasil FEM menggunakan MATLAB guna memungkinkan pendekatan DT dalam penilaian struktural. Kontribusi utama dari studi ini adalah perancangan alur kerja DT di mana data sensor SHM berfungsi sebagai masukan untuk simulasi FEM. Dengan mendemonstrasikan bagaimana simulasi numerik dapat memproses data SHM, menyelaraskannya dengan perpindahan yang diprediksi oleh FEM, serta mendeteksi anomali struktural, penelitian ini bertujuan untuk memberikan dasar bagi implementasi DT dalam skala nyata di bidang rekayasa struktur.

Sistem *Structural Health Monitoring* (SHM) melibatkan penggunaan sensor untuk memantau respons struktur secara waktu nyata terhadap beban lingkungan dan operasional. Data yang diperoleh dari SHM memberikan wawasan bagi para insinyur tentang kelelahan material, degradasi, serta potensi mekanisme kegagalan suatu struktur. Namun, data mentah dari SHM sering kali mengandung derau dan inkonsistensi, sehingga sulit untuk diintegrasikan langsung dengan model FEM. Oleh

karena itu, teknik fusi data canggih, seperti *Kalman filter* dan model pembelajaran mesin, semakin banyak digunakan untuk menyaring data SHM dan menyelaraskannya dengan hasil FEM.

Dalam konteks ini, *Kalman filter* dipilih karena kemampuannya dalam estimasi optimal. Pada dasarnya, *Kalman filter* adalah algoritma yang memberikan estimasi terbaik terhadap keadaan internal suatu sistem dengan memproses pengukuran sensor yang mengandung derau. Sebuah studi oleh Cadei et al. (Cadei, et al., 2020) memperkenalkan kerangka deteksi anomali untuk pemantauan waktu nyata pada fasilitas industri menggunakan analisis data lanjutan, yang menunjukkan bahwa metode deteksi anomali otomatis dapat meningkatkan akurasi deteksi kesalahan dan pemeliharaan prediktif. Studi lain oleh Lu et al. (Lu, Xie, Parlikad, & Schooling, 2020) menekankan pentingnya integrasi data untuk pemantauan aset bangunan, di mana data SHM waktu nyata digunakan dalam model prediktif berbasis *Digital Twin* untuk operasi dan pemeliharaan.

Sebagai representasi virtual dari sistem fisik, *Digital Twin* dapat memperbarui model secara berkelanjutan menggunakan data waktu nyata. Dalam bidang rekayasa struktur, DT berperan sebagai penghubung antara simulasi FEM dan data SHM, memungkinkan penilaian struktural secara waktu nyata serta pemeliharaan prediktif. Menurut penelitian oleh Opoku et al. (Opoku, Perera, Osei-Kyei, & Rashidi, 2021), DT telah banyak diterapkan dalam industri manufaktur, dirgantara, dan konstruksi, tetapi masih dalam tahap awal adopsi untuk infrastruktur sipil. Studi tersebut menyoroiti *Building Information Modeling* (BIM) sebagai faktor kunci dalam penerapan DT di industri konstruksi, dengan mengintegrasikan data geometri 3D, jadwal pembangunan, serta sensor untuk meningkatkan pemantauan dan pengambilan keputusan secara waktu nyata.

Studi lain oleh Rausch et al. (Rausch, Sanchez, Esfahani, & Haas, 2020) mengeksplorasi algoritma komputasi untuk mendukung DT dalam konstruksi, dengan menekankan bagaimana logika berbasis aturan dalam perangkat lunak BIM (seperti *Autodesk Revit* dan *Rhinoceros*) dapat dimanfaatkan untuk mengotomatisasi analisis struktural dan deteksi anomali. Sementara itu, penelitian oleh Lee et al. (Lee & Lee, 2021) mengusulkan kerangka kerja *Digital Twin* untuk konstruksi modular, di mana data sensor IoT waktu nyata diintegrasikan dengan simulasi logistik berbasis GIS untuk mengoptimalkan koordinasi rantai pasok serta prediksi risiko. Studi oleh Lu et al. (Lu, Xie, Parlikad, & Schooling, 2020) memperkenalkan sistem deteksi anomali berbasis DT untuk pemantauan aset, dengan menekankan aplikasinya dalam operasi dan pemeliharaan melalui struktur data berbasis IFC (*Industry Foundation Classes*).

Meskipun *Digital Twin* memiliki potensi besar dalam rekayasa struktur, Gierling et al. (Gierling & Dyck, 2021) menyatakan bahwa hingga saat ini belum ada definisi yang seragam mengenai apa yang disebut sebagai DT di berbagai industri. Beberapa peneliti mendefinisikan DT sebagai model waktu nyata yang terus diperbarui dan disinkronkan dengan sistem fisik, sementara yang lain memperluas konsep ini hingga mencakup pemodelan prediktif bahkan sebelum suatu struktur dibangun.

2. METODE PENELITIAN

Kalman filter adalah algoritma rekursif yang digunakan untuk mengestimasi keadaan tidak diketahui suatu sistem dengan menggabungkan data sensor yang mengandung derau dengan model prediktif. Dalam rekayasa struktur, *Kalman filter* dapat diterapkan untuk menyaring data SHM dan meningkatkan keselarasan dengan prediksi berbasis FEM. Sebuah tulisan oleh Rosafalco et al. (Rosafalco, Eftekhar Azam, Mariani, & Corigliano, 2024) membenarkan penggunaan filter Kalman untuk pembaruan digital twin berbasis FEM (*Finite Element Method*) secara *real-time*. Rosafalco et al. menunjukkan bahwa filter Kalman memungkinkan pembaruan online dari model numerik yang berfungsi sebagai digital twin struktur, sambil mengukur ketidakpastian dalam properti struktural yang diperkirakan. Studi ini menjelaskan algoritma pembaruan berbasis filter Kalman. Hal ini menegaskan bahwa penggunaan *Unscented/Extended Kalman filter* untuk terus-menerus mengoreksi model FE dengan data SHM yang masuk merupakan pendekatan yang sudah mapan untuk identifikasi sistem *real-time* pada struktur sipil.

Sebuah artikel dari Chen et al. (Chen, Xie, & Zhang, 2025) memperkuat diskusi metodologi ini tentang asimilasi data dan identifikasi parameter. Chen et al. mengembangkan “digital-physical twin” untuk sebuah struktur, yang mengintegrasikan data sensor tanpa kontak (misalnya, berbasis

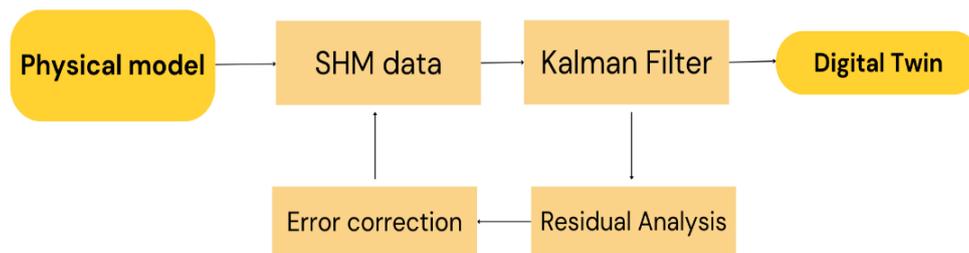
visi atau data inspeksi) dengan model FE, dan menggunakan algoritma filter Kalman untuk mengidentifikasi parameter penting yang memengaruhi kinerja struktural. Pekerjaan ini mendukung penggunaan filter Kalman untuk meredam kebisingan sensor dan memperbarui parameter model. Sebagai contoh, saat membahas bagaimana filter Kalman meningkatkan akurasi prediktif dengan menyelaraskan pengukuran SHM dengan simulasi FEM, pendekatan Chen et al. dapat disebut sebagai contoh terbaru dari kalibrasi multi-parameter dalam DT. Hal ini menunjukkan bahwa teknik kerangka kerja kami (penggabungan data dan pembaruan model) sejalan dengan praktik mutakhir untuk evaluasi kinerja struktural.

Dalam studi mereka, Lu et al. (Lu, Xie, Parlikad, & Schooling, 2020) menyoroti bahwa metode deteksi anomali berbasis titik (*point-based anomaly detection*) sering kali gagal menangkap variasi kontekstual dalam kondisi operasional. Sebagai alternatif, mereka mengusulkan metode deteksi perubahan berbasis *Bayesian Online Change-Point Detection* (BOCPD) yang lebih efektif dalam mengidentifikasi anomali struktural yang nyata serta menyaring hasil positif palsu (*false positive*). Dalam penelitian lain, Cadei et al. (Cadei, et al., 2020) mendemonstrasikan bagaimana *Kalman filter* dapat dimasukkan ke dalam kerangka deteksi anomali untuk memungkinkan identifikasi waktu nyata terhadap penyimpangan dari perilaku operasional normal. Dengan mengintegrasikan pemfilteran *Kalman* dalam model *Digital Twin*, insinyur dapat menciptakan simulasi FEM yang secara otomatis diperbarui, di mana penilaian struktural terus ditingkatkan berdasarkan data sensor waktu nyata.

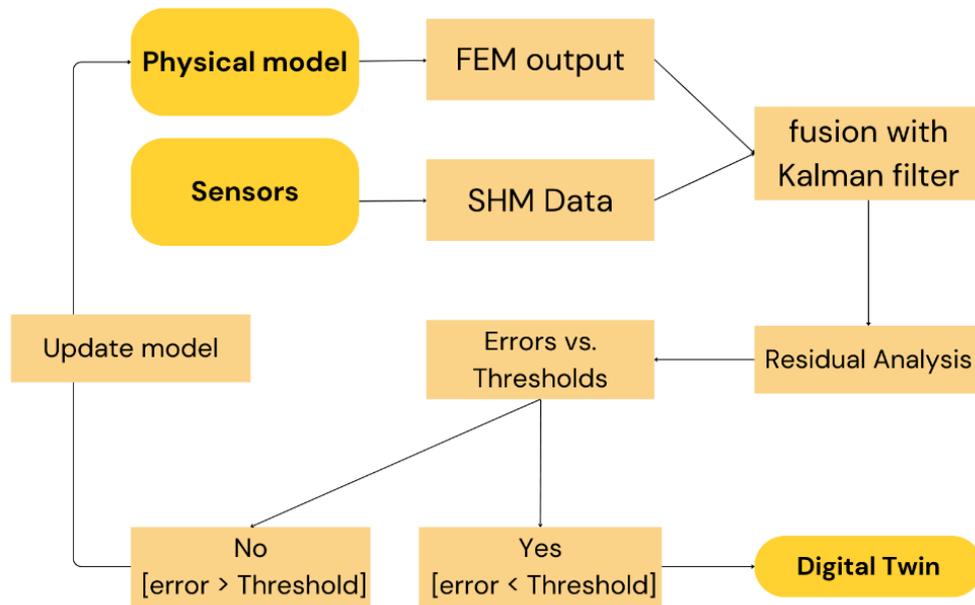
Meskipun *Digital Twin* menawarkan banyak keuntungan dalam rekayasa struktur, masih terdapat berbagai tantangan yang perlu diatasi, di antaranya:

1. Integrasi Data – Data SHM berasal dari berbagai sumber, sehingga sulit untuk disatukan ke dalam satu model *Digital Twin* berbasis FEM.
2. Kompleksitas Komputasi – Pembaruan FEM secara waktu nyata memerlukan daya pemrosesan yang tinggi, yang membatasi penerapannya untuk struktur berskala besar.
3. Kurangnya Standarisasi – Seperti yang dicatat oleh Gierling et al. (Gierling & Dyck, 2021), belum ada konsensus mengenai kerangka kerja implementasi *Digital Twin*, sehingga adopsinya masih terfragmentasi di berbagai industri.

Tantangan-tantangan tersebut dapat menjadi fokus penelitian di masa depan, khususnya dalam pengembangan model pembaruan FEM berbasis AI secara waktu nyata, teknik penyempurnaan FEM secara otomatis, serta protokol standar untuk pengembangan *Digital Twin* dalam rekayasa struktur.



Gambar 1. Visualisasi kerangka kerja



Gambar 2. Visualisasi ekstensi kerangka kerja

Bagian ini menguraikan kerangka konseptual untuk mengintegrasikan hasil simulasi FEM dengan data SHM menggunakan MATLAB. Pendekatan ini mencakup beberapa langkah utama untuk menjembatani kesenjangan antara perilaku struktural yang disimulasikan dengan pengukuran sensor di lapangan. Proses ini diawali dengan simulasi model FEM dan ekstraksi data. Data pertama diperoleh dari analisis FEM (misalnya, menggunakan SAP2000 atau ETABS) untuk mendapatkan respons struktural dasar, seperti perpindahan, tegangan, dan frekuensi modal. Langkah selanjutnya adalah pengumpulan data SHM dari pembacaan sensor, yang umumnya mengandung derau. Dalam penelitian ini, data SHM yang dihasilkan secara sintesis digunakan sebagai masukan kedua untuk meniru pengukuran dunia nyata. Kedua kumpulan data ini kemudian digunakan sebagai masukan awal dalam proses fusi data menggunakan *Kalman filter*.

Kalman filter diterapkan untuk menggabungkan prediksi FEM dengan pengukuran SHM, menyaring derau, dan menghasilkan estimasi respons struktural yang lebih halus. Dari sini, proses deteksi anomali dilakukan dengan menganalisis perbedaan antara prediksi FEM dan data SHM yang telah difilter. Proses iteratif dengan batas toleransi tertentu diterapkan untuk mengidentifikasi deviasi signifikan yang mungkin menunjukkan adanya anomali struktural.

Gambar 1 dan Gambar 2 diatas mengilustrasikan alur kerja integrasi simulasi FEM dengan data SHM. Model FEM memberikan respons struktural yang diharapkan berdasarkan kondisi yang diasumsikan, sedangkan sistem SHM menyediakan pengukuran aktual yang mengandung derau dan ketidakpastian. Dengan membandingkan dan menggabungkan kedua sumber data ini, kondisi kesehatan struktur dapat dinilai secara berkelanjutan.

Dalam pendekatan ini, *Kalman filter* digunakan sebagai alat fusi data untuk menggabungkan prediksi dari simulasi dengan pengukuran dari sensor, sementara logika deteksi anomali akan menandai setiap perbedaan signifikan di antara keduanya. Proses ini menciptakan umpan balik berkelanjutan, di mana prediksi FEM dan pembacaan SHM saling memperbarui, memungkinkan pemantauan waktu nyata serta penyempurnaan model di masa mendatang.

Secara garis besar, alur kerja ini mencakup:

1. Simulasi FEM menghasilkan prediksi perilaku struktural.
2. Sistem SHM mengumpulkan data dari sensor lapangan.
3. *Kalman filter* menggabungkan kedua data untuk menyaring derau.
4. Jika pengukuran SHM menyimpang di luar batas toleransi dari prediksi FEM, maka anomali terdeteksi.

Integrasi ini meningkatkan kepercayaan terhadap hasil pemantauan dan membuka jalan bagi pembaruan model yang lebih cerdas menggunakan kecerdasan buatan (AI).

Dalam studi ini, karena keterbatasan akses terhadap perangkat lunak FEM berbasis industri, data FEM sintetis dihasilkan menggunakan MATLAB untuk mewakili respons struktural yang diharapkan. Data sintetis ini berfungsi sebagai kondisi awal "sehat" dari struktur dan mencakup beberapa jenis keluaran yang biasanya diperoleh dari analisis FEM, yaitu:

- Riwayat Perpindahan: Respons perpindahan yang disimulasikan terhadap waktu (misalnya, akibat beban dinamis) menggunakan pola sinusoidal dengan sedikit variasi.
- Data Tegangan-Regangan: Respon tegangan-regangan ideal berdasarkan asumsi sifat material (untuk meniru hasil dari pengujian beban statis atau bertahap).
- Properti Modal: Frekuensi modal dan rasio redaman hipotetis yang menggambarkan karakteristik dinamis struktur.

Sebagai contoh, kode MATLAB berikut digunakan untuk membuat data riwayat perpindahan sintetis:

```
% Contoh: Menghasilkan data perpindahan FEM sintetis (riwayat waktu)
time = (1:1000)';
fem_disp = 5 * sin(0.01 * time) + 0.5 * randn(1000, 1);
% fem_disp sekarang mewakili perpindahan yang diprediksi oleh FEM
```

Dalam kode di atas, *fem_disp* adalah array berisi 1000 data perpindahan dalam domain waktu. Data ini terdiri dari gelombang sinusoidal dengan amplitudo 5-unit dan frekuensi 0,01 Hz, yang dikombinasikan dengan derau acak kecil ($0.5 * randn$) untuk meniru kesalahan pemodelan atau variabilitas kecil. Dalam skenario nyata, data ini akan berasal dari hasil analisis perangkat lunak FEM.

Untuk meniru pengukuran sensor di dunia nyata, data SHM sintetis dibuat dengan menambahkan derau tambahan ke data FEM yang telah dibuat sebelumnya. Data ini mensimulasikan apa yang akan direkam oleh sensor SHM, yang dipengaruhi oleh ketidakakuratan pengukuran, kondisi lingkungan, dan faktor eksternal lainnya.

Berikut adalah kode sederhana MATLAB untuk menghasilkan data SHM sintetis:

```
% Simulasi data sensor SHM dengan menambahkan derau pada data FEM
shm_disp = fem_disp + 0.2 * randn(1000, 1);
```

Dalam kode ini, *shm_disp* mewakili data perpindahan yang direkam oleh sensor akselerometer atau transduser perpindahan. Derau tambahan dengan deviasi standar 0.2-unit mencerminkan faktor-faktor seperti ketidakakuratan sensor atau gangguan eksternal. Angka ini tentu saja dapat disesuaikan melalui proses *tuning* lebih lanjut.

Langkah ini penting karena menciptakan skenario di mana dua deret waktu tersedia:

- “Respons struktural ideal” (data FEM)
- “Respons terukur” (data SHM dengan derau tambahan)

Data ini kemudian digunakan dalam tahap berikutnya, yaitu pemrosesan menggunakan *Kalman filter*.

Untuk menyelaraskan prediksi FEM dengan data SHM yang berisik, diterapkan *Kalman filter*. Algoritma ini merupakan estimator optimal yang dapat menyaring derau serta menggabungkan informasi dari berbagai sumber (dalam hal ini, model FEM dan sensor SHM) guna memperkirakan keadaan sebenarnya dari struktur. Asumsi model untuk implementasi *Kalman filter* dalam studi ini adalah:

- Model transisi keadaan $A = 1$ (mengasumsikan perpindahan tidak berubah secara signifikan dalam satu langkah waktu).
- Model pengukuran $C = 1$ (sensor langsung mengukur perpindahan).
- Kovarians derau proses $Q = 0.001$ (mengasumsikan bahwa model FEM cukup akurat).
- Kovarians derau pengukuran $R = 0.05$ (mengasumsikan sensor memiliki tingkat derau yang lebih tinggi dibandingkan model).

Kode sederhana MATLAB untuk implementasi *Kalman filter* adalah sebagai berikut:

```
% Inisialisasi parameter Kalman filter
A = 1; C = 1;
Q = 0.001; R = 0.05;
x_est = 0; P_est = 1;
kalman_estimates = zeros(1000, 1);
for t = 1:1000
    % Prediksi
    x_pred = A * x_est;
    P_pred = A * P_est * A' + Q;
    % Perhitungan Kalman gain
    K = P_pred * C' / (C * P_pred * C' + R);
    % Pembaruan dengan pengukuran SHM
    x_est = x_pred + K * (shm_disp(t) - C * x_pred);
    P_est = (1 - K * C) * P_pred;
    kalman_estimates(t) = x_est;
end
```

Hasil pemrosesan ini akan menghasilkan estimasi perpindahan yang lebih halus dan lebih sesuai dengan respons FEM ideal.

3. HASIL DAN PEMBAHASAN

Dengan tersedianya data hasil prediksi FEM dan data SHM yang telah difilter menggunakan *Kalman filter*, langkah selanjutnya adalah deteksi anomali. Dalam konteks ini, anomali didefinisikan sebagai perbedaan signifikan antara respons struktural yang diprediksi oleh model FEM dan respons aktual yang diukur oleh sensor SHM. Perbedaan ini dapat menunjukkan adanya perubahan kondisi struktur, seperti kerusakan, retak, atau degradasi material yang tidak diperhitungkan dalam model awal.

Pendekatan yang digunakan untuk mendeteksi anomali dalam penelitian ini adalah dengan menghitung deviasi residual, yaitu selisih absolut antara estimasi hasil *Kalman filter* dan prediksi FEM. Kemudian, ditentukan ambang batas (*threshold*) untuk membedakan variasi normal dan anomali. Ambang batas ini dihitung berdasarkan statistik dari data residual, dengan asumsi distribusi Gaussian di mana sekitar 95% nilai normal berada dalam rentang rata-rata ± 2 standar deviasi. Kode MATLAB berikut digunakan untuk mendeteksi anomali:

```
% Menghitung deviasi antara estimasi Kalman dan prediksi FEM
deviation = abs(kalman_estimates - fem_disp);

% Menentukan ambang batas deteksi anomali (rata-rata + 2 standar deviasi)
threshold = mean(deviation) + 2 * std(deviation);

% Menandai titik-titik yang melebihi ambang batas sebagai anomali
anomalies = deviation > threshold;
```

Dalam kode sederhana ini, variabel *anomalies* adalah vektor logika yang bernilai 1 (*true*) pada indeks di mana perbedaan antara respons model dan data SHM melebihi ambang batas yang telah ditentukan. Titik-titik ini dapat diinterpretasikan sebagai indikasi adanya anomali struktural yang memerlukan investigasi lebih lanjut. Jika jumlah anomali yang terdeteksi tinggi atau terjadi dalam pola tertentu (misalnya, terus meningkat dalam jangka waktu tertentu), maka kemungkinan besar terjadi degradasi atau perubahan signifikan dalam struktur yang perlu segera ditindaklanjuti melalui inspeksi fisik atau analisis lanjutan.

3.1 Pengembangan Masa Depan Untuk Pembaruan Model Berbasis AI

Pendekatan yang dijelaskan dalam penelitian ini dapat dikembangkan lebih lanjut dengan mengintegrasikan kecerdasan buatan (*Artificial Intelligence*) dan pembelajaran mesin untuk menciptakan sistem pemantauan struktural yang lebih cerdas dan adaptif. Beberapa arah pengembangan potensial meliputi:

1. Pembelajaran Mesin (*Machine Learning*) untuk Klasifikasi Anomali

Pendekatan berbasis ambang batas statistik dalam deteksi anomali memiliki keterbatasan, terutama dalam menangani variasi kompleks yang tidak dapat dijelaskan oleh model sederhana. Sebagai alternatif, metode klasifikasi berbasis AI, seperti jaringan saraf tiruan (*Neural Networks*) atau pembelajaran tak terawasi (*unsupervised learning*), dapat diterapkan untuk membedakan anomali akibat:

- Gangguan sensor (*sensor faults*).
- Variasi operasional normal (*operational variations*).
- Indikasi awal kegagalan struktural (*structural failure symptoms*).

Algoritma seperti *K-Means Clustering* atau *Autoencoders* dapat digunakan untuk mengelompokkan data historis dan mendeteksi pola yang menunjukkan awal mula degradasi struktural.

2. Penyempurnaan Model FEM Secara Otomatis

Saat terjadi perbedaan signifikan antara prediksi FEM dan pengukuran SHM, model FEM dapat diperbarui secara otomatis dengan menyesuaikan parameter seperti:

- Kekakuan material (*stiffness degradation*).
- Distribusi massa (*mass redistribution*).
- Kondisi batas (*boundary conditions*).

Pendekatan ini dapat dilakukan dengan metode optimasi berbasis *Bayesian Inference* atau teknik pemodelan inversi (*inverse modeling*) yang memperbarui model berdasarkan tren data waktu nyata.

3. Integrasi dengan IoT dan Komputasi Awan

Untuk meningkatkan efisiensi pemantauan dalam skala besar, sistem ini dapat dikombinasikan dengan *Internet of Things* (IoT), di mana sensor SHM terhubung ke platform berbasis *cloud computing*. Beberapa manfaat dari pendekatan ini meliputi:

- Pemantauan multi-struktur secara simultan (misalnya, jaringan jembatan atau gedung tinggi).
- Penyimpanan dan pemrosesan data berskala besar untuk analisis tren jangka panjang.
- Pemanfaatan kecerdasan buatan berbasis cloud untuk deteksi pola anomali dalam skala luas.

Dengan integrasi IoT, data dari berbagai sensor dapat dikirim ke server pusat untuk diproses dengan algoritma AI yang lebih kompleks. Sistem ini memungkinkan deteksi dini dan prediksi kegagalan sebelum terjadi kerusakan yang lebih parah.

4. Prediksi Umur Struktur dan Pemeliharaan Berbasis AI

Pengembangan lebih lanjut dapat mencakup model prognosis degradasi struktural, di mana data historis dan pemantauan waktu nyata digunakan untuk memperkirakan umur sisa suatu struktur (*Remaining Useful Life – RUL*). Model seperti *Hidden Markov Models* (HMM) atau *Long Short-Term Memory* (LSTM) *Networks* dapat digunakan untuk melakukan prediksi berbasis pola degradasi yang terdeteksi dari data SHM.

Dengan model ini, sistem tidak hanya dapat mendeteksi kerusakan yang telah terjadi, tetapi juga memprediksi kapan suatu bagian dari struktur kemungkinan besar akan mengalami kegagalan, sehingga jadwal pemeliharaan dapat direncanakan lebih efisien.

Mengambil referensi dari Yu et al. (Yu, Li, & Ou, 2022), mengindikasikan untuk dapat membandingkan kerangka kerja kami dengan implementasi dunia nyata. Yu et al. tidak hanya menggabungkan data dan model tetapi juga melakukan evaluasi kerusakan kelelahan pada digital

twin jembatan mereka. Demonstrasi konsep ini selaras dengan studi jembatan oleh Yu et al., di mana model DT membantu menginterpretasi data langsung untuk prognosis retak akibat kelelahan. Mengutip hasil mereka menyoroti bagaimana sebuah DT yang diperkaya dengan data sensor dapat menghasilkan wawasan diagnostik (misalnya, mengidentifikasi titik-titik stres atau umur kelelahan). Hal ini menegaskan bahwa kerangka kerja kami siap untuk membantu dalam diagnostik kesehatan struktural dan pemeliharaan prediktif, seperti halnya studi-studi yang telah terbukti di literatur.

Ye et al. (Ye, Yang, Yang, Huo, & Meng, 2020) dapat kembali kami kutip di sini untuk membahas kemampuan pemodelan prediktif dari digital twin. Studi kasus mereka menunjukkan bagaimana sebuah DT (yang diperbarui melalui *Extended Kalman filter*) dapat memprediksi degradasi struktural dan mendeteksi anomali selama masa layanan pesawat luar angkasa. Tulisan ini menegaskan bahwa memasukkan filter Kalman dalam DT memungkinkan manajemen kesehatan struktur yang proaktif. Temuan kami mencerminkan pendekatan dari Ye et al. (2020), yang mengintegrasikan digital twin berbasis EKF untuk terus-menerus memprediksi dan mengelola kesehatan struktural dalam pesawat luar angkasa, menunjukkan potensi luas dari teknik semacam itu untuk deteksi anomali tepat waktu. Perbandingan dengan keberhasilan studi yang sudah ada ini dapat memperkuat argumen bahwa pemodelan prediktif *real-time* melalui DT efektif untuk struktur yang kompleks.

4. KESIMPULAN

Penelitian ini telah menunjukkan bagaimana data SHM dapat diintegrasikan dengan simulasi FEM menggunakan pendekatan berbasis MATLAB. Dengan menghasilkan data sintetis yang mencerminkan hasil simulasi FEM dan pengukuran sensor, serta menerapkan *Kalman filter* untuk fusi data, metode ini menciptakan sistem pemantauan tertutup (*closed-loop monitoring system*). Hasil yang diperoleh menunjukkan bahwa:

- *Kalman filter* secara efektif mengurangi derau dan menyelaraskan data SHM dengan prediksi FEM.
- Ketika perbedaan antara hasil *Kalman filter* dan FEM melebihi ambang batas, sistem dapat mendeteksi anomali struktural secara otomatis.
- Dengan pendekatan ini, pemantauan struktural dapat ditingkatkan dari sistem statis (hanya berbasis simulasi FEM awal) ke sistem yang adaptif, di mana model FEM dapat diperbarui berdasarkan data sensor waktu nyata.

Mengutip dari Liu et al. (Liu, Lai, Bacsá, & Chatzi, 2023), penelitian ini menunjukkan bagaimana AI dan filter Kalman bersama-sama dapat memperkuat kerangka kerja. Liu et al. memperkenalkan pendekatan "*Neural EKF*", di mana *neural networks* digabungkan dengan *Extended Kalman filter* untuk mempelajari perilaku struktural yang kompleks dan meningkatkan akurasi prediksi. Dalam bagian kesimpulan ini, kami merujuknya sebagai jalur untuk diagnostik yang ditingkatkan dengan *machine learning*. Perluasan di masa depan dapat mengintegrasikan *machine learning*, seperti yang ditunjukkan oleh Liu et al. (2023), yang mencapai peningkatan prediktif yang signifikan dengan menggabungkan *neural networks* dengan *Kalman filter*. Hal ini menunjukkan kemungkinan deteksi kerusakan yang digerakkan oleh AI dan pembaruan model otomatis untuk DT yang lebih tangguh. Menyertakan kutipan ini menunjukkan bahwa kami menyadari perkembangan mutakhir (seperti menggabungkan *deep learning* dengan kerangka kerja DT) yang dapat dieksplorasi lebih lanjut untuk meningkatkan pemantauan *real-time* dan pemodelan prediktif dalam rekayasa struktur.

Ke depan, integrasi dengan AI dan IoT akan memungkinkan pengembangan DT yang lebih cerdas dan prediktif dalam rekayasa struktur. Implementasi metode pembelajaran mesin untuk klasifikasi anomali serta optimasi otomatis model FEM akan membawa sistem ini ke tingkat yang lebih lanjut, dengan manfaat utama berupa reduksi biaya pemeliharaan, peningkatan keselamatan, dan optimalisasi umur layanan struktur.

PERNYATAAN PENULIS

Penulis menyatakan berterimakasih kepada tim editor dan reviewer Jurnal Kajian Teknik Sipil (JKTS) dari Universitas 17 Agustus 1945 Jakarta yang telah memfasilitasi penerbitan tulisan ini. Penulis juga menyatakan bahwa penelitian ini dilakukan secara independen. Penulis tidak menerima dukungan eksternal dari institusi, organisasi, atau mitra industri selain pihak JKTS. Selain itu, penulis juga menyatakan bahwa tidak ada konflik kepentingan (*conflict of interest*) yang terkait dengan publikasi tulisan ini.

DAFTAR PUSTAKA

- Cadei, L., Rossi, G., Montini, M., Fier, P., Milana, D., Corneo, A., . . . Sophia, G. (2020). Achieving Digital-Twin Through Advanced Analytics Support: A NoveltyDetection Framework to Highlight *Real-time* Anomalies in Time Series. *International Petroleum Technology Conference IPTC-19834-MS*.
- Chen, Y., Xie, S., & Zhang, J. (2025). Structural performance evaluation via digital-physical twin and multi-parameter identification. *Automation in Construction*, 170. doi:<https://doi.org/10.1016/j.autcon.2024.105907>
- Glerlmg, J.-E., & Dyck, A. (2021). Maritime Digital Twin architecture-A concept for holistic Digital Twin application for shipbuilding and shipping. *De Gruyter Oldenbourg*, 69(12), 1081-1095.
- Lee, D., & Lee, S. (2021). Digital Twin for Supply Chain Coordination in Modular Construction. *Applied Sciences*, 11, 5909.
- Liu, W., Lai, Z., Bacsa, K., & Chatzi, E. (2023). Neural extended *Kalman filters* for learning and predicting dynamics of structural systems. *Structural Health Monitoring. Advance online publication*. doi:<https://doi.org/10.1177/14759217231179912>
- Lu, Q., Xie, X., Parlidak, A., & Schooling, J. (2020). Digital twin-enabled anomaly detection for built asset monitoring in operation and maintenance. *Automation in Construction*, 118, 103277.
- Opoku, D.-G., Perera, S., Osei-Kyei, R., & Rashidi, M. (2021). Digital twin application in the construction industry: A literature review. *Journal of Building Engineering*, 40, 102726.
- Rausch, C., Sanchez, B., Esfahani, M. E., & Haas, C. (2020). Computational Algorithms for Digital Twin Support in Construction. *Construction Research Congress 2020: Computer Applications*.
- Rosafalco, L., Eftekhari Azam, S., Mariani, S., & Corigliano, A. (2024). System identification via unscented *Kalman filtering* and model class selection. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, 10. doi:<https://doi.org/10.1061/AJRUA6.RUENG-1085>
- Ye, Y., Yang, Q., Yang, F., Huo, Y., & Meng, S. (2020). Digital twin for the structural health management of reusable spacecraft: A case study. *Engineering Fracture Mechanics*, 234. Diambil kembali dari <https://doi.org/10.1016/j.engfracmech.2020.107076>
- Yu, S., Li, D., & Ou, J. (2022). Digital twin-based structure health hybrid monitoring and fatigue evaluation of orthotropic steel deck in cable-stayed bridge. *Structural Control and Health Monitoring*, 8, 29. doi:<https://doi.org/10.1002/stc.2976>