

Pengembangan Model Estimasi Biaya Pemeliharaan Dan Perawatan Bangunan Gedung Dengan Artificial Neural Network

Eliza Rosmaya Puri^{1*}, Iris Mahani², Rani G. K. Pradoto³, dan Bangkit Krisna Satriadi⁴

^{1*,2,3,4}Program Studi Teknik Sipil, Institut Teknologi Bandung, Jl. Ganesa 10, Bandung

e-mail: eliza.puri@itb.ac.id, irism@itb.ac.id, ranipradoto@itb.ac.id

ABSTRAK

ABSTRAK Estimasi biaya pemeliharaan bangunan gedung secara konvensional seringkali tidak akurat karena pendekatannya yang bersifat reaktif dan tidak berbasis pada analisis data historis, sehingga menyebabkan proses penganggaran menjadi tidak tepat sasaran. Penelitian ini bertujuan untuk menguji potensi penggunaan *machine learning* dengan metode *Artificial Neural Network* (ANN) sebagai alat bantu estimasi yang lebih andal, serta mengidentifikasi komponen pekerjaan yang berpengaruh signifikan terhadap total biaya. Diawali dengan menerapkan metode *Cost Significant Items* (CSI) untuk menyeleksi fitur input yang paling dominan secara finansial, model prediksi dikembangkan menggunakan arsitektur ANN jenis *feedforward network* dengan konfigurasi 8-6-1, yang memanfaatkan data historis dengan jeda waktu 2 tahun ke belakang. Simulasi menunjukkan bahwa hasil pemodelan ANN menunjukkan performa yang sangat tinggi, dengan tingkat akurasi pada data uji mencapai *Mean Absolute Percentage Error* (MAPE) sebesar 0.029%. Temuan ini secara kuat mengindikasikan bahwa penerapan ANN memiliki potensi besar untuk mentransformasi praktik penganggaran pemeliharaan dari yang reaktif menjadi lebih proaktif, akurat, dan berbasis data.

Kata kunci: Estimasi biaya, Pemeliharaan Gedung, *Artificial Neural Network* (ANN)

1. PENDAHULUAN

Bangunan gedung merupakan wujud fisik hasil pekerjaan konstruksi yang menyatu dengan tempat kedudukannya, sebagian atau seluruhnya berada di atas dan/atau di dalam tanah dan/atau air, yang berfungsi sebagai tempat manusiamelakukan kegiatannya, baik untuk hunian atau tempat tinggal, kegiatan keagamaan, kegiatan usaha, kegiatan sosial, budaya maupun kegiatan khusus (UU Nomor 28 Tahun 2002, 2002). Berdasarkan UU Nomor 28 Tahun 2002 tentang Bangunan Gedung, sebuah bangunan gedung memiliki dua persyaratan, yakni administratif dan teknis. Salah satu persyaratan teknis bangunan gedung adalah aspek keandalan. Menjaga keandalan bangunan gedung sangat penting untuk menjamin kelaikan fungsi bangunan demi keselamatan dan kenyamanan penghuninya.

Selaras dengan Permen PU Nomor 24 Tahun 2008, pemeliharaan dan perawatan bangunan gedung merupakan bentuk manajemen aset bangunan untuk menjaga keamanan, kualitas, dan kinerja bangunan serta mengurangi biaya perbaikan besar di masa depan. Tanpa perencanaan dan estimasi yang tepat, biaya pemeliharaan dan perawatan dapat membengkak.

Ketidakpastian biaya dalam pemeliharaan dan perawatan menjadi tantangan bagi pengelola gedung, seperti kerusakan pada komponen tak terduga, faktor lingkungan, serta harga material yang fluktuatif. Hal ini menyebabkan rencana anggaran biaya pemeliharaan dan perawatan bangunan gedung tidak sesuai dengan yang terjadi di lapangan. Pada Gedung CIBE ITB, penganggaran biaya pemeliharaan ditetapkan pada awal tahun anggaran dengan nilai pagu. Pada pelaksanaannya kerap terjadi *underbudget* yang mengakibatkan pekerjaan pemeliharaan dan perawatan yang berjalan tidak maksimal, mulai dari penyerapan alokasi biaya pemeliharaan dan perawatan tahun selanjutnya, hingga penundaan pekerjaan pemeliharaan dan perawatan gedung yang berpotensi menimbulkan kerusakan yang lebih parah.

Estimasi biaya pemeliharaan dan perawatan harus mampu mempertimbangkan faktor yang kompleks, pola kerusakan historis dan tren jangka panjang, serta mampu memproyeksikan kebutuhan di masa depan. Tanpa adanya estimasi yang berbasis data, pagu anggaran yang ditetapkan bisa jadi tidak mencerminkan kebutuhan riil di tahun mendatang.

Dengan memanfaatkan pendekatan *machine learning*, kita dapat memproses data yang kompleks dan besar dengan akurat. Kemampuan *machine learning* dalam melakukan analisis pola historis berbagai variabel yang mempengaruhi biaya pemeliharaan dan perawatan dapat menghasilkan prediksi biaya yang lebih akurat dan efektif. *Artificial Neural Network* (ANN) menjadi salah satu metode *machine learning* yang mampu meningkatkan keakuratan dan epektivitas estimasi biaya pemeliharaan dan perawatan. Metode ANN menerapkan cara kerja berbasis jaringan saraf tiruan yang mensimulasikan cara kerja otak manusia dalam mengenali pola dan pembelajaran.

Penelitian ini bertujuan untuk mengembangkan model *machine learning* yang dapat menjadi dasar untuk menentukan pagu anggaran pemeliharaan yang lebih efektif dan dapat dipertanggungjawabkan. Harapannya, hasil penelitian ini

dapat bermanfaat bagi pihak pengelola gedung agar lebih efektif dan akurat dalam melakukan estimasi serta penganggaran biaya pemeliharaan dan perawatan bangunan gedung.

2. MACHINE LEARNING


Menurut Goodfellow et al. (2016) dalam buku *Deep Learning, Machine Learning* adalah sebuah bidang studi yang memungkinkan komputer untuk belajar dari pengalaman (data) dan meningkatkan performanya tanpa diprogram secara eksplisit. Dalam konteks pemeliharaan dan perawatan bangunan gedung, *machine learning* dapat digunakan untuk melakukan estimasi biaya pemeliharaan dan perawatan berdasarkan pola historis dari berbagai variabel seperti usia bangunan, jumlah kegagalan, luas bangunan, faktor lingkungan, dan laporan biaya pemeliharaan historis. Menurut Goodfellow et al. (2016), Machine learning dibagi menjadi tiga kategori utama:

1. *Supervised Learning*. Model ini belajar dari data berlabel di mana setiap input memiliki output yang sudah diketahui sebelumnya. Contohnya adalah regresi linier, random forest, dan Artificial Neural Network (ANN).
2. *Unsupervised Learning*. Model ini menemukan pola atau struktur dalam data yang tidak memiliki label. Contohnya adalah clustering dan PCA (Principal Component Analysis).
3. *Reinforcement Learning*. Model ini belajar melalui interaksi dengan lingkungan dan mendapatkan umpan balik dalam bentuk *reward* atau *punishment*. Contohnya adalah algoritma Q-learning dan Deep Q Networks.

Artificial Neural Network

Artificial Neural Network atau jaringan syaraf tiruan merupakan salah satu representasi otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran. Penggunaan istilah tiruan dalam definisi tersebut sehubungan dengan pendekatan sistem jaringan syaraf yang diimplementasikan dalam suatu program komputer yang mampu menyelesaikan sejumlah proses perhitungan setelah melalui mekanisme pembelajaran (Kusumadewi, 2004). ANN menjadi pilihan sebagai *cost model* dalam perhitungan biaya pemeliharaan dan perawatan karena keunggulannya dalam kemampuan pembelajaran dan generalisasi dibandingkan dengan *cost model* lainnya.

Jaringan antar neuron mampu memecahkan masalah kompleks dengan solusi analitik terhadap keterbatasan data numerik. Konfigurasi arsitektur pada metode ANN berpengaruh pada pencapaian nilai output yang sesuai terhadap target dengan nilai error yang kecil. Metode ANN memiliki teknik pembelajaran berupa *backpropagation*. Dalam konteks ANN, istilah arsitektur mengacu pada struktur jaringan saraf tiruan, yang mencakup jumlah lapisan, jumlah neuron pada setiap lapisan, dan bagaimana setiap neuron dihubungkan satu sama lain.



Gambar 1. Artificial Neural Network
Sumber: Bre and Gimenez, 2017

Perancangan arsitektur ANN melibatkan analisis data, identifikasi variabel estimasi biaya pekerjaan struktur serta pemilihan arsitektur jaringan. Penentuan arsitektur berupa jumlah hidden layer rencana serta jenis fungsi waktu. Persamaan ANN secara umum sebagai berikut.

$$Y = f(\sum W_n X_n)$$

Dengan: Y : prediksi output, W_n : bobot korespondensi, X_n : variabel input, f : fungsi transfer yang digunakan.

3. METODE PENELITIAN

Untuk mencapai tujuan penelitian di atas, dikembangkan metodologi penelitian yang mencakup tahapan berikut. Pada tahap pertama, model estimasi nilai biaya berbasis ANN pada penelitian sebelumnya dipelajari. Pada tahap kedua,

model ANN dirancang untuk estimasi nilai biaya pekerjaan pemeliharaan dan perawatan gedung. Kemudian model diuji untuk mendapatkan konfigurasi jaringan arsitektur model terbaik. Simulasi dilakukan dengan menggunakan data satu kasus pemeliharaan dan perawatan gedung 8 lantai (2 basemen & 6 lantai) tahun 2019-2024.


4. MODEL MACHINE LEARNING

Pemodelan *machine learning* sendiri dikembangkan dengan tahapan berikut.

1. Pada pemodelan machine learning dimulai dengan melakukan input data biaya pemeliharaan Bangunan Gedung CIBE ITB tahun 2019-2024. Selanjutnya dilakukan konfigurasi parameter dengan menentukan *source* yang akan dijadikan input di dalam *machine learning*, serta menentukan jumlah eksperimen yang akan dilakukan. Setelah data dipastikan dapat terbaca, selanjutnya dilakukan pembacaan data yang ada dan melakukan normalisasi untuk menghindari variasi data yang begitu besar.

Pengklasifikasian didasarkan pada Permen PU No. 24 Tahun 2008 yang terdiri dari pekerjaan pemeliharaan (*preventive maintenance*) dan perawatan (*corrective maintenance*). Enam lingkup utama pemeliharaan dan perawatan gedung digunakan dalam agregasi data, yakni pekerjaan arsitektural, struktural, mekanikal, elektrik, tata ruang luar, dan tata graha. Setelah melakukan rekapitulasi dan analisis tren historis komponen pekerjaan, berikut disajikan data mengenai rasio biaya pada pekerjaan *preventive maintenance* dan *corrective maintenance*.

Berdasarkan analisis *Cost Significant Items* (CSI) yang dilakukan pada 10 komponen biaya maintenance, ditemukan bahwa 4 komponen yang secara kumulatif menyumbang 80,85% dari total biaya maintenance diantaranya: Pekerjaan Arsitektural Lantai, Pekerjaan Lift, dan Tata Graha. Komponen ini akan digunakan sebagai variabel input model *Artificial Neural Network* (ANN).



Gambar 2. (kiri) Grafik Rasio Biaya Maintenance 2019-2024 (kanan) Tabel Penentuan Komponen Uji CSI

2. Tahap selanjutnya adalah membuat rekayasa fitur pada *machine learning* dan melakukan pembagian data sebagai data latih dan data uji. Untuk memberikan konteks historis, pada model, dilakukan rekayasa fitur dengan menerapkan Jeda Waktu (Lag) 2 tahun ke belakang. Pembagian data dilakukan dengan data tahun 2019-2023 sebagai Data Latih, dan data tahun 2024 sebagai Data Uji.

Dalam model regresi yang dibangun untuk pengujian ini, variabel-variabel didefinisikan sebagai berikut.

- Variabel Dependen (Y) : Total Biaya Pemeliharaan Tahunan
- Variabel Independen (X) : Biaya Tahunan Komponen Pekerjaan Hasil Analisis Uji *Cost Significant Items* (CSI)


Desain arsitektur dan alur pemodelan dilakukan dengan langkah (a) Rekayasa Fitur dan Lag dan (b) Penentuan Arsitektur Jaringan. Berdasarkan 3 fitur input dan 1 fitur target dengan jeda 2 tahun, maka dapat dibentuk sebuah vektor input dengan total 8 node. Berikut perumusan jumlah node pada input.

$$Node = (n \text{ Fitur input} \times n \text{ Lag}) + (n \text{ Fitur target} \times n \text{ Lag})$$

Selain itu, terdapat *rule of thumb* yang dikemukakan oleh Jeff Heaton dalam bukunya yang berjudul *Introduction to Neural Network with Java*, menyebutkan bahwa penentuan jumlah hidden layers berada pada 2/3 ukuran input layer ditambah dengan ukuran output layer. Pada penelitian ini digunakan hidden layer dengan jumlah 6. Oleh karena itu, arsitektur ANN yang digunakan adalah (8-6-1) yang terdiri dari:

1. Satu Input Layer dengan 8 node.
2. Satu Hidden Layer dengan 6 neuron yang berfungsi sebagai “otak” pemroses informasi.
3. Satu Output Layer dengan 1 neuron yang menghasilkan satu nilai prediksi akhir.

Setiap koneksi antar neuron memiliki bobot (weight) yang nilainya akan disesuaikan selama proses belajar. Bobot ini merepresentasikan kekuatan pengaruh dari satu neuron ke neuron lainnya.



Gambar 3. Arsitektural Pemodelan ANN (8-6-1)

3. Selanjutnya akan masuk ke dalam tahap subproses pemodelan *Artificial Neural Network* (ANN), yakni pencarian model terbaik melalui 100 kali eksperimen. Output model terbaik dari eksperimen ANN akan digunakan untuk melakukan tahap selanjutnya, yakni Validasi Data Uji dan forecasting untuk tahun rencana.

Proses “belajar” ANN dilakukan secara iteratif menggunakan data historis dari tahun 2019 hingga 2023 sebagai Data Latih, sementara data tahun 2024 “disembunyikan” dan digunakan sebagai Data Uji untuk proses validasi.

- a. Penentuan *Random Seed Optimal*. Pada awal pelatihan dimulai dengan nilai bobot awal acak (*seed*). Untuk menemukan titik awal acak yang paling optimal dan menghindari hasil yang kebetulan, dilakukan eksperimen sebanyak 100 kali. Eksperimen dengan nomor seed yang menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) terendah pada data uji, akan dipilih untuk digunakan. Hal ini dilakukan untuk memastikan hasil yang didapat adalah yang terbaik dan dapat direpliasi.
- b. Proses Training. Proses training melibatkan kegiatan iteratif yang sering disebut dengan metode backpropagation. Dengan seed terbaik, model akan dilatih untuk membaca pola pembobotan biaya pemeliharaan tiap komponen untuk membentuk Total Biaya. Model akan mengambil Data Latih, membuat tebakan berupa bobot tiap komponen, membandingkannya dengan “kunci jawaban” berupa data Total Biaya Aktual tiap tahunnya (2019-2023), menghitung nilai error, lalu mengirimkan sinyal koreksi ke belakang (backpropagation) untuk menyesuaikan nilai bobotnya. Proses “tebak-koreksi” ini akan berulang terus menerus hingga model menemukan kombinasi bobot yang menghasilkan pembobotan yang optimal. Pembobotan optimal merupakan kombinasi pembobotan dengan nilai error paling rendah.
- c. Validasi Data Uji Setelah proses training (2019-2023) selesai, model dengan kombinasi pembobotan final akan “dikunci” untuk diuji kemampuannya menggunakan Data Uji 2024 tanpa melihat “kunci jawaban” berupa Total Biaya Aktual 2024. Keberhasilan pada tahap ini menunjukkan kemampuan generalisasi model.

Selanjutnya dengan pemodelan ANN di atas, output model ANN terbaik akan dilakukan untuk melakukan validasi menggunakan data uji. Apabila hasilnya memiliki *error* yang rendah, maka model akan digunakan untuk peramalan/forecasting. Hasil *forecasting* yang masih dalam skala normalisasi akan dilakukan denormalisasi menjadi skala rupiah.

5. HASIL DAN PEMBAHASAN

Faktor yang Berpengaruh Signifikan

Tabel 1. Rekapitulasi Hasil Uji T Parsial

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	108565024.8	31800521.31		3.414	.042
	Lift	1.654	.180	.933	9.202	.003
	Lantai	1.673	.568	.299	2.948	.060

Upaya untuk menerapkan analisis Regresi Linear Berganda dan Uji T Parsial ini menghadapi tantangan berupa multikolinearitas dan keterbatasan jumlah data historis. Setelah melalui proses diagnosis dan penyederhanaan model dengan hanya menyertakan dua komponen dominan yang tidak berkorelasi tinggi (Komponen Lift dan Arsitektural

Lantai), analisis Uji T Parsial dapat dijalankan.

Berdasarkan tabel di atas, dengan menggunakan kriteria signifikansi $p \text{ value} < 0,05$, ditemukan bahwa variabel Komponen Lift memiliki nilai signifikansi sebesar 0,003. Nilai ini menunjukkan bahwa Pekerjaan Lift memiliki pengaruh yang sangat signifikan secara statistik terhadap Total Biaya. Hasil statistik ini sangat selaras dengan hasil rekapitulasi biaya maintenance dimana Komponen Pekerjaan Lift menyumbang sebanyak 37,44%. Apabila kita tinjau berdasarkan kondisi nyata di lapangan, Lift Gedung CIBE ITB memang memiliki riwayat kerusakan yang tinggi, terutama lift sebelah selatan. Biaya maintenance yang dikeluarkan untuk perbaikan lift juga memiliki nilai yang tinggi. Selain itu kompleksitas sistem mekanikal dan elektrik pada lift, kebutuhan tenaga ahli khusus, dan biaya spare parts mendukung terpilihnya komponen ini sebagai komponen yang berpengaruh signifikan. Berbeda dengan Komponen Arsitektural Lantai ($\text{sig} = 0,06$) yang meskipun secara nominal biayanya ada, pengaruhnya tidak cukup kuat secara statistik untuk dinyatakan signifikan dalam model.

Kinerja Model Prediktif ANN

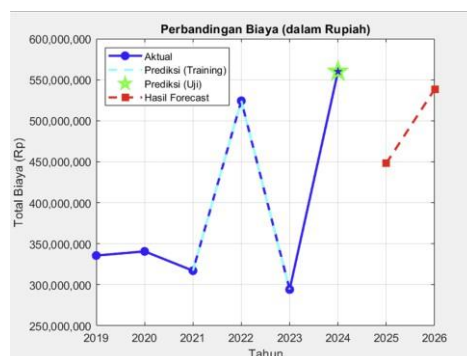
Kinerja sebuah model prediktif diukur dari kemampuannya untuk menghasilkan estimasi yang sedekat mungkin dengan nilai aktualnya, terutama pada data yang belum pernah dilihat sebelumnya. Hasil dalam pemodelan Artificial Neural Network (ANN) dievaluasi secara kuantitatif menggunakan dua metrik utama, yakni *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

Tabel 2. Performa Model Final

Metrik	Data Latih	Data Uji
<i>Root Mean Squared Error</i> (RMSE)	0.00000	0.00048
<i>Mean Absolute Percentage Error</i> (MAPE)	0.000000%	0.028742%

Berdasarkan tabel di atas, model yang dikembangkan berhasil mencapai nilai MAPE pada data uji sebesar 0,029%. Nilai ini menunjukkan tingkat akurasi yang sangat tinggi. Secara praktis, ini berarti rata-rata kesalahan prediksi model kurang dari seperseribu persen terhadap nilai biaya aktualnya. Secara teknis, performa ini didukung oleh nilai RMSE (dalam skala normalisasi) sebesar 0,00048 yang menjadi indikator bahwa model tidak menghasilkan kesalahan prediksi tunggal yang ekstrem.

Perbandingan antara performa data latih ($\text{MAPE} \approx 0.00\%$) dengan data uji ($\text{MAPE} = 0.0295\%$) menunjukkan adanya selisih yang sangat kecil dan wajar. Hal ini menandakan bahwa model tidak mengalami overfitting secara signifikan dan mampu mengaplikasikan pola yang telah dipelajarinya pada data baru dengan sangat baik. Overfitting adalah kondisi dimana model ANN belajar "terlalu baik" sehingga ia tidak hanya mempelajari pola umum yang penting, tetapi juga menghafal gangguan dan detail yang tidak relevan dari data tersebut. Akibatnya model hanya memiliki performa yang tinggi pada data latih, tetapi buruk ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya (validation atau test data). Berikut merupakan rincian perbandingan nilai aktual, prediksi per tahun, serta forecast tahun 2025 dan 2026.



Tabulasi Nilai Error (Skala Normalisasi)			
Tahun	Aktual	Prediksi	<i>Mean Absolute Percentage Error</i> (MAPE)
2021	0.1689	0.1689	0.000000721%
2022	0.7918	0.7918	0.000000079%
2023	0.1000	0.1000	0.000000467%
2024	0.9000	0.8995	0.053818150%

Hasil Final Forecasting (Rupiah)	
Tahun	Prediksi Biaya Pemeliharaan
2025	Rp448,303,317.00
2026	Rp538,447,753.00

Gambar 4. Perbandingan Biaya Aktual, Prediksi (Training dan Uji), Tabulasi Nilai Error, dan Forecast

Berdasarkan hasil peramalan pada tabel di atas, menunjukkan adanya proyeksi tren yang non-linear. Setelah biaya aktual pada tahun 2024 sebesar ~Rp 560,2 juta, model memprediksi adanya penurunan biaya pada tahun 2025 menjadi ~Rp 448,3 juta. Namun model kemudian memprediksi adanya kenaikan biaya pada tahun 2026 menjadi ~Rp 538,45 juta. Pola ini mengindikasikan bahwa "memori pembobotan" internal model telah berhasil menangkap siklus atau hubungan yang lebih kompleks dalam data historis, bukan hanya sekedar melanjutkan tren garis lurus sederhana. Biaya diprediksi turun drastis di tahun 2025 sebelum kemudian melonjak kembali di tahun 2026. Temuan ini memberikan wawasan penting bagi pengelola gedung bahwa faktor-faktor dari tahun sebelumnya dapat menciptakan fluktuasi biaya yang signifikan di masa depan.

Meskipun demikian, hasil pemodelan dengan error yang kecil ini perlu diinterpretasikan dengan hati-hati terutama dengan pertimbangan karakteristik dataset yang digunakan. Tingkat error yang sangat rendah ini kemungkinan besar dipengaruhi oleh jumlah data historis yang sangat terbatas. Pelatihan ANN yang hanya menggunakan data 6 tahun merupakan sampel yang sangat kecil untuk melatih model yang kompleks. Terlebih lagi, karena validasi hanya dilakukan pada satu titik data uji tunggal, yakni data tahun 2024, terdapat kemungkinan bahwa akurasi tinggi yang didapatkan adalah sebuah kebetulan statistik karena titik data uji ini secara kebetulan memiliki karakteristik yang sangat mirip dengan data latih.

Validasi Logika Peramalan Model ANN

Berdasarkan analisis kualitatif pola perilaku pemeliharaan dan perawatan hasil peramalan pada tahun 2025 akan turun sebelum naik kembali pada tahun 2026. Hal ini sesuai dengan kecenderungan bahwa anggaran yang dialokasikan pada tahun 2024 akan menyerap sebagian dari anggaran maintenance tahun 2025. Tingginya angka prediksi untuk tahun 2026 merupakan hasil dari model yang memproyeksikan bahwa terdapatnya backlog pemeliharaan dan perawatan tahun 2025 yang harus diselesaikan. Analisis logika model ANN secara implisit dapat mempelajari pola perilaku anggaran yang reaktif. Model dapat melihat data historis bahwa sebuah tahun dengan biaya sangat tinggi (2022) cenderung diikuti oleh sebuah tahun dengan biaya yang sengaja ditekan (2023).

Meskipun kuantifikasi backlog pemeliharaan dan perawatan tidak dapat dilakukan karena keterbatasan data pada dokumen *defect list*, analisis kualitatif ini secara kuat memvalidasi "kecerdasan" model ANN, dimana model tidak hanya akurat secara matematis yang ditunjukkan oleh error yang rendah, tetapi hasil prediksinya juga logis jika dihubungkan dengan konteks kejadian nyata dan pola keputusan manajerial.

Tanpa adanya dasar estimasi yang kuat, sistem penganggaran berdasarkan pagu rentan tidak sesuai dengan kebutuhan riil sehingga beresiko menciptakan siklus pembengkakan biaya, yang diikuti oleh penundaan pekerjaan, dan berakhir menjadi *backlog* pemeliharaan dan perawatan. Hal ini akan menimbulkan biaya yang lebih besar di tahun-tahun berikutnya. Dengan menggunakan pemanfaatan *machine learning* sebagai dasar penentuan pagu anggaran, estimasi yang dilakukan dapat mempelajari pola/karakteristik pemeliharaan dan mengantisipasi potensi lonjakan biaya di masa depan. Selain itu dapat menghindari pengorbanan pemeliharaan penting yang justru akan menjadi "bom waktu" di tahun-tahun selanjutnya.

Pada akhirnya, implementasi model prediktif ini dapat menjadi jembatan untuk mentransformasi praktik pemeliharaan dan perawatan yang bersifat reaktif menjadi lebih prediktif dan berbasis data yang jelas, sehingga meningkatkan efisiensi dan keandalan manajemen aset gedung secara keseluruhan.

6. KESIMPULAN

Berdasarkan pemodelan dan analisis yang dilakukan dalam penelitian tugas akhir ini, didapatkan kesimpulan sebagai berikut.

1. Model estimasi biaya pemeliharaan dan perawatan bangunan gedung yang dikembangkan menggunakan metode *machine learning* (*Artificial Neural Network*) terbukti menghasilkan estimasi yang akurat dengan dibuktikan dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,029% dibandingkan dengan biaya aktual.
2. Berdasarkan analisis sensitivitas yang dilakukan pada model *machine learning*, teridentifikasi satu komponen bangunan yang memberikan pengaruh paling signifikan terhadap besaran biaya pemeliharaan dan perawatan yakni Komponen Pekerjaan *Lift* dengan nilai signifikansi 0,003.

DAFTAR PUSTAKA DAN PENULISAN PUSTAKA

Mukhlis, I. R., Marisa, Dede Hertina, Mk., Rima Rachmawati, Ms., Ir Wati Asriningsih Pranoto, C., Dhian Marita Sari, M., Ns Erlin Ifadah, Mp., Ir Sa, S. H., & Yulia NKWasaraka, I. (2023). *TEKNIK PENULISAN KARYA ILMIAH*. www.buku.sonpedia.com

Nurhayati, S., Kurnianta, P. D., & Anggraeni, A. F. (2024). *PENGANTAR KARYA TULIS* <https://www.researchgate.net/publication/381805342> ILMIAH.

Panudju, A. T., & Purba, F. (2024). *METODOLOGI PENELITIAN*. <https://www.researchgate.net/publication/377847335> Permen PU Nomor 24 Tahun 2008. (2008).

Saha, Swapan. (2015). *Implementing innovative ideas in structural engineering and project management*. ISEC Press.

UU Nomor 28 Tahun 2002. (2002).