

Pengaruh Variasi *Hidden Layer* Terhadap Nilai MAPE Pada Pengembangan Model Estimasi Biaya Menggunakan *Artificial Neural Network* (Studi Kasus: Biaya Peningkatan Jalan Aspal di D.I.Yogyakarta)

**I Made Sutrisna Ari Kesuma¹, Arief Setiawan Budi Nugroho^{*2},
Akhdad Aminullah³**

^{1,2,3} Departemen Teknik Sipil dan Lingkungan, Universitas Gadjah Mada
Jl. Grafika No.2, Kabupaten Sleman, Daerah Istimewa Yogyakarta

Submitted : 29, Mei, 2023;

Accepted: 30, Oktober, 2023

Abstrak

Pekerjaan peningkatan jalan menjadi suatu kebutuhan yang tidak dapat dielakkan guna mendapatkan infrastruktur transportasi yang lebih handal. Dukungan perencanaan anggaran dan estimasi biaya yang baik oleh karenanya harus dilakukan. Model persamaan prediksi anggaran dan biaya dengan *Artificial Neural Network (ANN)* menjadi alternatif solusinya. ANN menuntut rancangan arsitektur jaringan yang tepat guna memperoleh model dengan tingkat akurasi yang tinggi. Penelitian ini bertujuan mengetahui jumlah efektif *neuron* dalam *hidden layer* yang memberikan hasil model persamaan ANN dengan tingkat akurasi tinggi dengan nilai *Mean Absolute Percentage Error (MAPE)* kecil. Pengembangan model didasarkan pada 33 data pekerjaan peningkatan jalan aspal di Provinsi Daerah Istimewa Yogyakarta dari tahun 2010 sampai dengan tahun 2021. Delapan belas variabel proyek yang berpengaruh signifikan terhadap total biaya pekerjaan digunakan sebagai data *input* model ANN dan dianalisis dengan berbagai variasi data model dan validator. Hasil penelitian menunjukkan bahwa variasi jumlah *neuron* dalam *hidden layer* menghasilkan nilai MAPE dengan pola tidak beraturan yang mana tingkat akurasi sangat dipengaruhi oleh data *input* dan validator. Namun demikian secara umum model dengan jumlah *neuron* dalam *hidden layer* $1\frac{1}{3}$ kali lipat dari jumlah variabel *input* menjanjikan hasil akurasi paling tinggi.

Kata Kunci : *artificial neural network; hidden layer; model analisis biaya; peningkatan jalan aspal*

Abstract

Road improvement work is an inevitability to achieve better transportation infrastructure reliability. Thus, reasonable budget and cost estimation planning must be carried out. Artificial Neural Network (ANN) is one of the answers which offer good mathematical models. However, ANN requires an appropriate network architecture design to obtain a model with a high degree of accuracy. The research objective is to determine the effective

number of neurons in the hidden layer for the ANN model equation that yields high accuracy with small value of Mean Absolute Percentage Error (MAPE). The model was developed using 33 data from a similar project of asphalt road improvement in the Special Region of Yogyakarta Province from 2010 until 2021. Eighteen project variables were determined as the significant influence factors on the total project cost, used as the entry data, and analyzed with various models and validators. The result shows that the variation number of neurons in the hidden layer produces a random pattern of the MAPE value. The data model and validator dominantly influenced the level of accuracy. However, in general, models with the number of neurons in the hidden layer being 11/3 times the number of input variables promise the highest accuracy results.

Keywords : *artificial neural network; hidden layer; cost analysis model; asphalt road improvement*

A. PENDAHULUAN

Peningkatan infrastruktur jalan menjadi suatu keniscayaan guna mencapai keandalan prasarana transportasi yang lebih baik. Secara umum prasarana jalan dibangun untuk mempercepat perpindahan antarwilayah serta mempermudah kegiatan penyaluran distribusi barang logistik dan jasa (Junoasmono et al., 2020). Infrastruktur yang mendapat beban dari volume lalu lintas yang *massive* dan berulang dapat mengakibatkan penurunan mutu layanan jalan (Karyawan et al., 2021). Selain itu, perubahan suhu dan cuaca serta kurangnya pemeliharaan rutin menjadi penyebab kerusakan jalan (Munggarani & Wibowo, 2017). Untuk menangani permasalahan tersebut, dibutuhkan pekerjaan peningkatan jalan guna meningkatkan kemantapan jalan dan umur layanannya.

Pekerjaan peningkatan jalan merupakan kegiatan yang dilakukan untuk memperbaiki fasilitas umum (jalan) yang sudah ada menjadi lebih baik menggunakan anggaran biaya yang bervariasi. Berdasarkan data yang diperoleh dari Dinas Pekerjaan Umum, Perumahan dan Kawasan Permukiman (PUPKP) Kabupaten Sleman dan Dinas Pekerjaan Umum (PU) Yogyakarta, total biaya kegiatan pekerjaan peningkatan

jalan aspal di Provinsi D.I Yogyakarta dari tahun 2010 hingga tahun 2021 mencapai ± 600 milyar. Mengingat besarnya kebutuhan biaya yang ada, prediksi dan pengendalian yang efektif menjadi sangat diperlukan untuk meminimalisir pengeluaran anggaran yang berlebihan.

Estimasi biaya merupakan bagian awal yang esensial dilakukan pada saat menyusun RAB pekerjaan konstruksi. Pada tahap awal data perencanaan dan spesifikasi pekerjaan belum tersedia, sehingga perhitungan perkiraan biaya secara kasar umumnya dilakukan dengan ketidaklengkapan data dan informasi yang tersedia (Winalytra et al., 2018). Di sisi lain, kurangnya ketelitian dan waktu yang terbatas dalam estimasi biaya dapat mempengaruhi kualitas hasil perhitungan (Roring et al., 2014). Agar perhitungan estimasi biaya dapat dilakukan dengan akurat dan mudah dipahami diperlukan pengembangan model estimasi biaya yang hasilnya mampu mendekati nilai aktual sebuah proyek. *Artificial Neural Network* (ANN) adalah salah satu metode pendekatan yang dimanfaatkan untuk memprediksi biaya dengan tingkat kesalahan yang rendah (Dewanti et al., 2021). Bila dibandingkan dengan metode lain, ANN memiliki kelebihan dalam pembelajaran yang cepat, kemampuan

untuk menggeneralisasi data dan tidak memerlukan validasi data statistik (Matel et al., 2022).

ANN membutuhkan rancangan arsitektur jaringan yang tepat untuk mendapatkan model persamaan estimasi biaya dengan nilai *error* yang kecil. Namun dalam penentuan jumlah *neuron* dalam *hidden layer* (HL) pada ANN dilakukan dengan model empiris bukan secara teoritis. Hal tersebut disebabkan karena tidak adanya aturan penentuan jumlah *neuron* dalam *hidden layer* maka dilakukan dengan cara *trial* dan *error* (Kardan et al., 2013). Dalam praktiknya, penggunaan jumlah *neuron* dalam *hidden layer* berlebihan dapat menyebabkan *overfitting*. Sedangkan, apabila jumlah *neuron* yang digunakan terlalu sedikit, dapat membuat model yang dibangun mengalami *underfitting* (Pothuganti, 2018). Penelitian ini bertujuan mengetahui jumlah efektif *neuron* dalam *hidden layer* yang memberikan hasil model persamaan ANN dengan tingkat akurasi terbaik (nilai MAPE kecil).

B. TINJAUAN PUSTAKA

1. Faktor Pengaruh Estimasi Biaya Proyek Jalan

Perhitungan estimasi biaya pada proyek jalan dapat dipengaruhi oleh beberapa faktor yang memiliki dampak signifikan terhadap total biaya pekerjaan. Dalam pelaksanaan proyek jalan, biaya pada pekerjaan perkerasan aspal memiliki pengaruh 30-50% dari total biaya pada RAB pekerjaan (Ratnawati et al., 2018). Selain itu, komponen biaya pekerjaan yang memiliki signifikan nilai biaya besar yaitu pekerjaan lapis pondasi bawah agregat kelas B, lapis pondasi atas agregat kelas A, lapis resap pengikat, lapis perekat, lapis AC-WC dan lapis AC-BC (Andeva dkk., 2018).

Estimasi biaya juga dipengaruhi oleh faktor laju inflasi tahunan dan suku

bunga dan waktu sehingga dilakukan penyeragaman biaya untuk menentukan nilai riil dari suatu proyek (Roxas et al., 2019). Penelitian lain yang dilakukan Handayani et al., (2015) untuk mengetahui item-item pekerjaan yang memiliki pengaruh signifikan terhadap total RAB pekerjaan, dilakukan dengan pengurutan persentase bobot biaya pekerjaan terbesar dan diakumulasikan hingga mencapai $\geq 80\%$.

2. Metode ANN pada Estimasi Biaya

Metode ANN dapat menghasilkan model persamaan empiris berdasarkan hubungan variabel *input* terhadap *output* dalam bentuk linier maupun non-linear (Al Suhili & Mohammed, 2014). Variabel *input* merupakan variabel bebas dengan jumlah data masukkan yang dapat berubah-ubah, sementara variabel *output* merupakan variabel terikat dengan nilai keluaran yang dipengaruhi oleh jumlah data masukkan pada variabel *input* (Harahap et al., 2022). Berbagai macam variasi pemodelan estimasi biaya metode ANN telah banyak dikembangkan. Penelitian perkiraan atau estimasi biaya untuk proyek pekerjaan jalan aspal di Provinsi D.I Yogyakarta menghasilkan model ANN dengan nilai MAPE terendah sebesar 8,13% pada *hidden layer* dengan *neuron* berjumlah 15 (Tahapari, 2021). Penggunaan metode ANN untuk estimasi biaya juga dilakukan pada 57 proyek jalan yang selesai dibangun. Hasil penelitian menjelaskan bahwa kinerja model ANN terbaik diperoleh pada *hidden layer* dengan *neuron* berjumlah 21 (Tadesse & Dinku, 2017). Disamping itu, untuk memprediksi estimasi biaya pemeliharaan proyek jalan dilakukan dengan menggunakan bentuk arsitektur ANN 7-6-1 (7 *input layer*, 6 *neuron* dalam *hidden layer*, dan 1 target *output*). Hasil penelitian menunjukkan bahwa tingkat keakuratan model, berada pada rentang 10% sampai dengan 15% (Shrestha & Shrestha, 2016). Penelitian

lain yang relevan terkait penggunaan model ANN untuk optimasi biaya pekerjaan jalan pada tahap konseptual juga menghasilkan nilai MAPE sebesar 32,58% (Tijanić dkk., 2020).

C. METODE PENELITIAN

1. Data Penelitian

Data sekunder yang digunakan dalam penelitian ini yaitu 31 data paket pekerjaan jalan aspal 2010 sampai dengan tahun 2019 (Tahapari, 2021) dan 2 data paket pekerjaan peningkatan jalan aspal Dinas PUPKP Kabupaten Sleman tahun 2020 hingga 2021. Data paket pekerjaan yang diperoleh dan diolah berupa Rencana Anggaran Biaya (RAB) yang disusun berdasarkan *Detail Engineering Design* (DED). Menurut Direktorat Jenderal Bina Marga, spesifikasi umum pekerjaan peningkatan jalan aspal terbagi dalam 10 divisi utama. Masing-masing item pekerjaan pada setiap divisi utama dilakukan analisis biaya dengan *Time Value of Money* (TVM). Analisis TVM mengkonversi keseluruhan nilai biaya proyek ke tahun anggaran pembahasan yang sama. Penelitian ini juga memperhitungkan faktor penyebab nilai laju inflasi tahunan dengan menggunakan *Cost Conversion Factor* (CCF) (Winalytra dkk., 2018). Nilai CCF dapat dihitung berdasarkan persamaan berikut:

$$CCF = (1 + f_p) \cdot (1 + f_{pn}) \cdot (1 + f_{n-1}) \quad (1)$$

Keterangan :

CCF = *Cost conversion factor* pada tahun implementasi pekerjaan
 f_p = Inflasi tahun implementasi pekerjaan
 n = Tahun bahasan, tahun 2022
 f_{n-1} = Tingkat inflasi tahun 2021

Hasil analisis biaya yang didapatkan dengan metode TVM dan CCF pada setiap item-item pekerjaan

dalam divisi utama, kemudian dilakukan juga pemilihan komponen biaya yang merepresentasikan nilai kumulatif bobot pekerjaan sebesar $\geq 80\%$.

2. Metode ANN

Dalam penelitian ini, variabel *input* (X) berupa nilai pekerjaan yang berpengaruh besar terhadap RAB yang merepresentasikan $\geq 80\%$ kumulatif bobot pekerjaan, sedangkan variabel *output* (Y) adalah total biaya pekerjaan. Analisis metode ANN dilakukan menggunakan bantuan perangkat lunak yaitu *Matrix Laboratory* (MATLAB). Sehubungan MATLAB hanya dapat mengenali data *entry* berupa besaran angka dalam rentang 0 sampai dengan 1, normalisasi data variabel *input* dan variabel *output* diperlukan sebelum proses analisis dilakukan. Normalisasi data menggunakan teknik *Z-Score*, yang digunakan untuk memberikan keseragaman data dan nilai yang stabil terhadap *outlier* (Al-Faiz dkk., 2018). Analisis *Z-Score* dilakukan berdasarkan persamaan:

$$Z\text{-Score} = \frac{\text{Data}-\text{Mean}}{\text{Stv.Dev}} \quad (2)$$

Pengolahan data dengan metode ANN terdiri dari tiga tahap meliputi tahap pemodelan, tahap pelatihan dan tahap validasi. Tahap pemodelan melibatkan pemilihan variabel *input*, variabel *output*, perancangan arsitektur jaringan dan analisis data. Sementara itu, tahap pelatihan dilakukan dengan pemilihan variasi pemodelan dan parameter pembelajaran, sedangkan tahap validasi dilakukan untuk mengetahui keakuratan persamaan empiris yang diperoleh dari model ANN pada tahap pelatihan.

Pada tahap pelatihan, data dibagi menjadi data *testing* dan data validasi. Pembagian data menggunakan teknik *cross-validation* yang mana sejumlah (K-1) data *testing* digunakan untuk *training*

pengembangan model ANN dan satu data sebagai validasi (Leni et al., 2023). Dari 33 data yang tersedia, 32 data dipilih menjadi data *testing* dan sisanya menjadi data validator. Analisis ini dilakukan secara berulang sebanyak 15 kali dengan mengubah data *testing* dan data validasi secara bergantian.

Pelatihan model ANN dilakukan menggunakan jumlah *neuron* dalam *hidden layer* (HL) yang bervariasi meliputi 16, 18, 20, 22, 24, 26 dan 28. Setiap variasi HL dilakukan *training* sebanyak 100 kali dan diambil lima data hasil pemodelan ANN yang memiliki nilai MAPE terkecil. Teknik pelatihan yang digunakan yaitu *backpropagation algorithm* (BPA) dengan metode *gradient descent (traingdx) with momentum*. Teknik pelatihan *backpropagation* dipilih karena kemampuannya dalam menghasilkan algoritma pembelajaran dengan interkoneksi yang tepat dari sejumlah *neuron* untuk menyesuaikan bobot-bobot yang terhubung pada arsitektur jaringan. Hasil pelatihan yang diperoleh dari masing-masing model ANN, dilakukan evaluasi keakuratan menggunakan nilai *Mean Square Error* (MSE) (Kassaymeh et al., 2022). Nilai MSE dapat dihitung dengan persamaan:

$$MSE = \frac{\sum (\text{Aktual}-\text{Estimasi})^2}{\text{Jmlh.data}} \quad (3)$$


Keunggulan lain dengan teknik pelatihan *backpropagation* yaitu adanya kondisi *stopping*. Hal ini terjadi apabila tingkat akurasi yang dihasilkan bernilai lebih kecil dari tingkat akurasi maksimum yang telah ditentukan sebelumnya yaitu 10% (Sari & Latief, 2021).

Data validasi dipilih secara berurutan untuk mengevaluasi tingkat kesalahan atau *error* (nilai MAPE) masing-masing pemodelan ANN. Nilai

MAPE dihitung dengan persamaan berikut:

$$MAPE = \frac{\sum |\text{Aktual}-\text{Estimasi}|}{\text{Aktual}} \times 100\% \quad (4)$$

Langkah-langkah dalam analisis ANN ditunjukkan pada Gambar 1.



Gambar 1. Langkah-langkah analisis ANN

D. HASIL DAN PEMBAHASAN

1. Analisis *Time Value of Money* (TVM)

Berdasarkan hasil pengumpulan dan pemilahan data, tersedia 33 data paket pekerjaan yang berasal dari tahun anggaran yang berbeda untuk dilakukan analisis TVM. Seluruh data biaya pekerjaan proyek diproyeksikan ke tahun anggaran pembahasan yaitu tahun 2021 dengan mempertimbangkan laju inflasi tahunan D.I. Yogyakarta dan perhitungan nilai CCF.

Tabel 1. Data penelitian

No	Tahun	Jumlah Paket	Laju Inflasi (%)	CCF
1	2010	1	7,38	1,59
2	2013	2	7,32	1,38
3	2014	1	6,59	1,28
4	2015	3	3,09	1,20
5	2016	1	2,29	1,17
6	2017	6	4,20	1,14
7	2018	15	2,66	1,09
8	2019	2	2,77	1,07
9	2020	1	1,40	1,04
10	2021	1	2,29	1,02
Total		33		

Tabel 1 menunjukkan bahwa penyebaran jumlah paket pekerjaan peningkatan jalan aspal di setiap tahunnya dengan persentase laju inflasi

dan nilai CCF. Nilai CCF yang diperoleh, kemudian dikalikan dengan biaya item-item pekerjaan pada divisi utama dalam RAB proyek menyesuaikan tahun pelaksanaan konstruksi.

2. Variabel Penelitian

Hasil identifikasi komponen biaya diketahui bahwa terdapat 18 variabel *input* dan 1 variabel *output*. Variabel *input* berupa biaya pada item-item pekerjaan dalam divisi utama yang berpengaruh besar terhadap RAB pekerjaan (X), sedangkan variabel *output* berupa total biaya pekerjaan peningkatan jalan aspal (Y). Pemilihan item-item pekerjaan dalam divisi utama dilakukan berdasarkan pengurutan persentase (%) bobot pekerjaan terbesar dan diakumulasikan hingga mencapai nilai akumulasi $\geq 80\%$. Hasil analisis persentase bobot biaya divisi pekerjaan ditampilkan pada tabel 2. Dari 10 divisi utama pekerjaan peningkatan jalan aspal, terdapat empat divisi pekerjaan memiliki persentase kumulatif bobot biaya pekerjaan mencapai $\geq 80\%$, meliputi divisi 6 (perkerasan aspal) sebesar 39,27%, divisi 2 (drainase) sebesar 23,87%, divisi 5 (perkerasan berbutir) sebesar 12,51% dan divisi 7 (struktur) sebesar 9,13%.

Tabel 2. Analisa persentase bobot biaya divisi pekerjaan

No.	Deskripsi	Jumlah Biaya Divisi dari 33 Pekerjaan (Rp)	Bobot Biaya	Kumulatif Bobot
1	Perkerasan aspal	228.873.563.498	39,27%	39,27%
2	Drainase	139.131.506.503	23,87%	63,14%
3	Perkerasan berbutir	72.902.644.893	12,51%	75,65%
4	Struktur	53.217.059.733	9,13%	84,78%
5	Pekerjaan tanah	43.024.062.532	7,38%	92,16%
6	Pelebaran perkerasan dan bahu jalan	23.900.488.281	4,10%	96,26%
7	Pekerjaan minor	15.835.922.276	2,72%	98,97%
8	Umum	4.190.752.285	0,72%	99,69%
9	Pekerjaan pemeliharaan rutin	1.456.907.450	0,25%	99,94%
10	Pekerjaan harian	327.959.534	0,06%	100,00%
Total Biaya Pekerjaan		582.860.866.984		

Metode yang sama dilakukan juga untuk memilih item-item pekerjaan dalam empat divisi utama yang memiliki nilai akumulasi $\geq 80\%$ mempengaruhi biaya masing-masing divisi. Hasil pemilihan item pekerjaan dari setiap divisi ditampilkan pada tabel 3.

Tabel 3 menunjukkan bahwa terdapat beberapa pekerjaan dalam divisi utama yang memiliki biaya pekerjaan nol (0) atau tidak tersedia dalam RAB pekerjaan. Item-item pekerjaan tersebut

contohnya terdapat pada biaya dalam divisi drainase, pekerjaan pasangan batu dengan mortar (X_4), baja tulangan untuk beton minor (X_5), beton K250/f'c 20 (X_6), saluran U tipe DS 3 (X_7), galian untuk saluran drainase (X_8), saluran U Tipe DS 2 (X_9), dan saluran U ($0,6 \times 0,8$) (X_{10}). Sedangkan, item pekerjaan pasangan batu (X_{15}) dalam divisi struktur merupakan satu-satunya item pekerjaan yang memiliki nilai pada keseluruhan 33 data paket pekerjaan.

Tabel 3. Variabel penelitian

Variabel	Deskripsi	Rentang Biaya (Rp)	Bobot Biaya (%)
X ₁ X ₂ X ₃	Divisi 6. Perkerasan aspal		80,66
	Laston lapis aus (AC-WC)	0 s.d. 7.920.807.552	32,27
	Laston lapis antara (AC-BC)	0 s.d. 9.870.189.291	25,84
	Laston lapis antara perata (AC-BC (L))	0 s.d. 6.435.699.608	22,55
X ₄ X ₅ X ₆ X ₇ X ₈ X ₉ X ₁₀	Divisi 2. Drainase		83,77
	Pasangan batu dengan mortar	0 s.d. 9.178.810.826	28,54
	Baja tulangan untuk beton minor	0 s.d. 7.762.792.657	22,13
	Beton K250/f'c 20	0 s.d. 3.245.682.676	11,95
	Saluran U tipe DS 3	0 s.d. 31.062.875.296	6,96
	Galian untuk saluran drainase	0 s.d. 1.256.771.979	5,06
	Saluran U Tipe DS 2	0 s.d. 1.986.812.314	4,62
	Saluran U ($0,6 \times 0,8$)	0 s.d. 2.776.406.637	4,51
X ₁₁ X ₁₂ X ₁₃ X ₁₄	Divisi 5. Perkerasan berbutir		82,99
	Lapis pondasi agregat kelas A	0 s.d. 6.743.267.243	45,29
	Lapis pondasi agregat kelas B	0 s.d. 9.881.736.385	15,03
	Lapis pondasi agregat semen kelas A (CTB)	0 s.d. 5.410.918.871	13,23
	Perkerasan beton semen	0 s.d. 3.132.095.359	9,44
X ₁₅ X ₁₆ X ₁₇ X ₁₈	Divisi 7. Struktur		82,96
	Pasangan batu	2.954.603 s.d. 3.271.392.950	51,63
	Beton mutu f'c 10	0 s.d. 1.886.111.719	12,94
	Beton mutu f'c 15	0 s.d. 748.338.343	12,62
	Bata tulangan ulir 32	0 s.d. 7.421.802.083	5,78
Y	Total Biaya Peningkatan Jalan Aspal	3.503.778.283 s.d. 89.602.006.847	


3. Pemodelan ANN

Model ANN dilakukan dengan variabel *input* dan *output* berdasarkan rancangan arsitektur jaringan seperti ditampilkan pada gambar 2. Variabel X_i pada *input layer* merupakan jumlah data *input* dengan *neuron* ke- i ($i=1, 2, 3, \dots, 18$), Z_j pada *hidden layer* merupakan jumlah variasi *neuron* ke- j ($j=16, 18, 20, 22, 24, 26, \text{ dan } 28$), dan variabel Y_k pada *output layer* merupakan jumlah data target *output* dengan satu *neuron*. Dalam

menghubungkan *input layer* ke *hidden layer* terdapat bobot penghubung yaitu $V_{[i,j]}$ dan bobot akhir bias *input* yaitu $V_{[i,0]}$, sedangkan untuk menghubungkan *hidden layer* ke *output layer* terdapat bobot penghubung yaitu $W_{[k,j]}$ dan bobot akhir bias lapisan yaitu $W_{[k,0]}$.

Analisis pemodelan ANN dilakukan dengan 18 variabel *input* yang terdiri dari biaya pekerjaan laston lapis aus (AC-WC) (X_1), laston lapis antara (AC-BC) (X_2), laston lapis antara perata (AC-BC

(L)) (X_3), pasangan batu dengan mortar (X_4), baja tulangan untuk beton minor (X_5), beton K250/f'c 20 (X_6), saluran U tipe DS 3 (X_7), galian untuk saluran drainase (X_8), saluran U tipe DS 2 (X_9), saluran U ($0,6 \times 0,8$) (X_{10}), lapis pondasi agregat (kelas A (X_{11}), lapis pondasi agregat kelas B (X_{12}), lapis pondasi agregat semen kelas A (CTB) (X_{13}), perkerasan beton semen (X_{14}), pasangan batu (X_{15}), beton mutu f'c 10 (X_{16}), beton mutu f'c 15 (X_{17}), dan bata tulangan ulir 32 (X_{18}) dengan variabel *output* yaitu biaya keseluruhan pekerjaan (Y).



Gambar 2. Rancangan arsitektur ANN

Pada pelatihan model digunakan konfigurasi arsitektur jaringan ANN, yaitu 1 *input layer* dengan 18 *neuron*, 1 *hidden layer* dengan variasi jumlah *neuron* (16, 18, 20, 22, 24, 26, dan 28), dan 1 *ouput layer* dengan 1 *neuron*. Seluruh data yang digunakan sebagai *training* dan *testing* dinormalisasi dengan *Z-score*, kemudian dilatih pada *software* MATLAB berdasarkan parameter fungsi aktivasi *sigmoid biner* (*logsig*) untuk *input layer*, *sigmoid tangent* (*tansig*) untuk *output layer* dan algoritma pelatihan jaringan *backpropagation* dengan maksimal jumlah iterasi (*epochs*) 13.000, target kesalahan 0,001, laju

pembelajaran (α) 0,1, *inc learning rate* 1,2, *dec learning rate* 0,6, periode (*epoch show*) 1.000, dan tren (*momentum*) 0,75. Hasil pelatihan ANN pada *software* MATLAB ditampilkan pada tabel 4.

Tabel 4. Hasil pelatihan ANN pada *software* MATLAB

Neuron Dalam Hidden Layer	Iterasi	MSE	R
16 HL	1.178	0,0009796	0,99949
18 HL	1.038	0,0009990	0,99948
20 HL	572	0,0009997	0,99949
22 HL	560	0,0009999	0,99948
24 HL	1.901	0,0009991	0,99948
26 HL	1.489	0,0009977	0,99949
28 HL	1.279	0,0009997	0,99949

Berdasarkan tabel 4, diketahui bahwa hasil pelatihan model ANN menggunakan *software* MATLAB, penggunaan *hidden layer* dengan *neuron* berjumlah 22 menghasilkan nilai MSE 0,0009999 terbaik dengan iterasi terkecil yaitu 560 dibandingkan *hidden layer* (HL) dengan *neuron* berjumlah 16, 18, 20, 24, 26 atau 28. Namun demikian secara keseluruhan nilai regresi (R) seluruh model ANN dengan variasi jumlah *neuron* dalam *hidden layer* memiliki hubungan yang kuat antara variabel *input* dengan *output*.

4. Validasi Model ANN

Validasi dilakukan untuk menguji hasil pelatihan model ANN. Setiap data yang dipilih sebagai validator, tidak dipergunakan untuk pengembangan model ANN. Lima belas data paket pekerjaan dipilih secara berurutan sebagai data validator. Analisis MAPE dilakukan untuk mengetahui keakuratan estimasi biaya hasil model ANN yang dibandingkan dengan nilai aktual biaya pekerjaan data validator. Hasil analisis estimasi biaya data validator seluruh model ANN dengan variasi jumlah *neuron* dalam *hidden layer* (HL) disajikan pada tabel 5, sedangkan pola


variasi *hidden layer* terhadap nilai MAPE ditunjukkan pada gambar 4.

Gambar 4 menunjukkan bahwa variasi jumlah *hidden layer* terhadap nilai MAPE membentuk suatu pola acak dimana nilai MAPE berfluktuasi pada validasi data model dan variasi jumlah *neuron* dalam *hidden layer* (HL) yang berbeda. Berdasarkan seluruh variasi *hidden layer* yang digunakan, *hidden layer* dengan 24 *neuron* memberikan nilai rata-rata MAPE terendah sebesar 0,79%. Penggunaan jumlah *neuron* dalam *hidden layer* yang sama (18 *neuron*) atau lebih rendah (16 *neuron*) dari jumlah variabel

input (X), menghasilkan nilai rata-rata MAPE masing-masing 1,04% dan 1,30%. Sementara itu, nilai rata-rata MAPE tertinggi didapat pada model ANN dengan *hidden layer* berjumlah 26 *neuron*. Hal ini menunjukkan bahwa untuk mencapai model ANN dengan tingkat akurasi yang tinggi (nilai MAPE kecil), jumlah *neuron* dalam *hidden layer* sebaiknya $1\frac{1}{3}$ kali dari jumlah variabel *input* (X). Dalam penelitian ini dengan 18 jumlah variabel *input* nilai rata-rata MAPE terendah diperoleh melalui *training data testing* dengan 24 *neuron* dalam *hidden layer*.

Tabel 5. Validasi model estimasi biaya ANN

Data Validator	Biaya Aktual (Rp. miliar)	Estimasi Biaya ANN (Rp. miliar)						
		16 HL	18 HL	20 HL	22 HL	24 HL	26 HL	28 HL
Proyek Jalan A	30,950	31,352	31,000	31,761	31,657	31,291	30,325	32,384
Proyek Jalan B	12,735	12,779	12,771	12,870	12,816	12,734	12,713	12,585
Proyek Jalan C	63,920	65,531	63,752	62,044	64,652	63,987	61,176	62,432
Proyek Jalan D	28,112	28,433	28,442	27,577	28,168	28,155	28,054	28,820
Proyek Jalan E	25,189	25,599	24,789	26,284	24,810	23,971	23,985	25,645
Proyek Jalan F	55,153	54,183	53,797	53,126	55,386	54,988	56,459	54,388
Proyek Jalan G	7,152	7,103	7,120	7,243	7,223	7,128	6,903	6,953
Proyek Jalan H	9,099	9,057	9,097	9,090	9,219	8,887	8,782	8,994
Proyek Jalan I	8,251	7,989	8,430	8,318	8,011	8,288	8,470	8,449
Proyek Jalan J	11,142	11,136	11,093	11,559	11,318	11,143	10,844	11,066
Proyek Jalan K	10,021	10,139	9,808	10,282	10,181	10,052	9,970	9,869
Proyek Jalan L	11,624	11,561	11,629	11,628	11,808	11,656	11,285	11,506
Proyek Jalan M	8,157	8,373	7,947	7,898	8,206	8,111	7,852	8,298
Proyek Jalan N	7,217	7,149	7,117	7,001	7,190	7,207	7,138	7,090
Proyek Jalan O	9,671	9,782	9,712	9,573	9,995	9,761	9,533	9,381



Gambar 4. Pola variasi *hidden layer* terhadap nilai MAPE

E. KESIMPULAN

Hasil penelitian menunjukkan bahwa terdapat 18 faktor atau item pekerjaan peningkatan jalan aspal (variabel) yang mempengaruhi estimasi biaya. Secara umum model estimasi biaya peningkatan jalan aspal dengan metode ANN dan variasi jumlah *neuron* dalam *hidden layer* (HL) mendapatkan nilai MAPE relatif rendah (dibawah 5%).

Sementara itu tingkat akurasi hasil pemodelan ANN dipengaruhi oleh keteraturan data model dan validator. Simulasi pengaruh data validator dan jumlah *neuron hidden layer* yang bervariasi, menghasilkan pola yang acak terhadap perubahan nilai MAPE. Nilai rata-rata MAPE terkecil diperoleh pada model ANN dengan 24 *neuron* dalam *hidden layer*, yaitu 0,79%. Hasil ini menunjukkan bahwa model ANN dengan tingkat akurasi terbaik diperoleh jika jumlah *neuron* dalam *hidden layer* $1\frac{1}{3}$ kali dari jumlah variabel *input* (X). Penggunaan jumlah *neuron* dalam *hidden layer* yang lebih kecil atau lebih besar dari $1\frac{1}{3}$ kali dari jumlah variabel *input* (X) menghasilkan model ANN dengan nilai rata-rata MAPE lebih besar. Hasil ini menunjukkan bahwa model ANN menjanjikan nilai MAPE terbaik jika jumlah *neuron* dalam *hidden layer* tidak kurang namun juga jangan terlalu jauh lebih besar dari jumlah variabel *input* (X). Oleh karena itu, untuk mendapatkan model ANN yang baik dengan tingkat ketelitian yang tinggi, diperlukan uji coba ulang pemodelan dengan penambahan jumlah *neuron* dalam *hidden layer* secara bertahap. *Neuron* dalam *hidden layer* dimulai sejumlah sama dengan variabel *input* (X) sampai dengan sejumlah $1\frac{1}{3}$ kali jumlah variabel *input* (X). Hasil model persamaan ANN terbaik ditetapkan berdasarkan hasil validasi yang mendapatkan nilai MAPE terkecil.

DAFTAR PUSTAKA

- Al-Faiz, M. Z., Ibrahim, A. A., & Hadi, S. M. (2018). The Effect of Z-Score Standardization (Normalization) on Binary Input Due The Speed of Learning in Back-propagation Neural Network. *Iraqi Journal of Information & Communications Technology*, 1(3), 42–48.
<https://doi.org/10.31987/ijict.1.3.41>
- Al Suhili, R. H., & Mohammed, Z. J. (2014). Comparison Between Linear and Non-linear ANN Models for Predicting Water Quality Parameters at Tigris River. *Journal of Engineering*, 20(10), 1–15.
<https://doi.org/10.31026/j.eng.2014.10.01>
- Andeva, H., Khamistan, & Zulfikar. (2018). Estimasi Anggaran Biaya dan Metode Pelaksanaan Pada Proyek Pembangunan Jalan Paloh Puntipulo–Iboh Kota Lhokseumawe. *Jurnal Sipil Sains Terapan*, 1(2), 23–31.
- Dewanti, R., Aminullah, A., & Priyosulistyo, H. (2021). Estimasi Biaya Struktur Gedung Rumah Sakit dengan Bentuk Persegi Panjang Menggunakan Metode Artificial Neural Network. *Journal of Civil Engineering and Planning*, 2(2), 139.
<https://doi.org/10.37253/jcep.v2i2.5351>
- Harahap, K. F., Aminullah, A., Teknik, M., Departemen, S., Sipil, T., Sipil, T., Teknik, D., Universitas, L., Teknik, D., Departemen, S., Sipil, T., & Mada, G. (2022). *Estimasi Dimensi Optimum Dan Rasio Tulangan Gedung Hotel Yogyakarta Dengan Artificial Neural Network*. 16(3), 182–190.
<https://doi.org/10.21831/inersia.v18i1>

- Junoasmono, T., Gultom, H. S. A., Umboh, B. S. C., & Sutandi, A. C. (2020). Pengembangan Jaringan Jalan Nasional Di Sulawesi Utara dan Gorontalo. *Jurnal Transportasi*, 20(1), 67–76.
<https://doi.org/10.26593/jtrans.v20i1.3857.67-76>
- Kardan, A. A., Sadeghi, H., Ghidary, S. S., & Sani, M. R. F. (2013). Prediction of Student Course Selection in Online Higher Education Institutes Using Neural Network. *Computers and Education*, 65, 1–11.
<https://doi.org/10.1016/j.compedu.2013.01.015>
- Karyawan, I. D. M. A., Hasyim, & Faqihi, K. (2021). Penurunan Masa Pelayanan Jalan Akibat Kendaraan Dengan Beban Berlebih. *Paduraksa: Jurnal Teknik Sipil Universitas Warmadewa*, 10(1), 56–69. doi : 10.22225/pd.10.1.2292.56-69
- Kassaymeh, S., Al-Laham, M., Al-Betar, M. A., Alweshah, M., Abdullah, S., & Makhadmeh, S. N. (2022). Backpropagation Neural Network Optimization and Software Defect Estimation Modelling Using A Hybrid Salp Swarm optimizer-Based Simulated Annealing Algorithm. *Knowledge-Based Systems*, 244, 108511.
<https://doi.org/10.1016/j.knosys.2022.108511>
- Khamistan. (2019). Analisis Estimasi Biaya Dengan Metode Cost Significant Model Sebagai Dasar Perhitungan Konstruksi Jembatan Beton Bertulang Di Kabupaten Aceh Tamiang. *Teras Jurnal*, 8(2), 444.
<https://doi.org/10.29103/tj.v8i2.168>
- Leni, D., Yermadona, H., Usra Berli, A., Sumiati, R., & Haris, H. (2023). Pemodelan Machine Learning untuk Memprediksi Tensile Strength Aluminium Menggunakan Algoritma Artificial Neural Network (ANN). *Jurnal Surya Teknika*, 10(1), 625–632.
<https://doi.org/10.37859/jst.v10i1.4843>
- Matel, E., Vahdatikhaki, F., Hosseinyalamdary, S., Evers, T., & Voordijk, H. (2022). An Artificial Neural Network Approach for Cost Estimation of Engineering Services. *International Journal of Construction Management*, 22(7), 1274–1287.
<https://doi.org/https://doi.org/10.1080/15623599.2019.1692400>
- Munggarani, N. A., & Wibowo, A. (2017). Kajian Faktor-Faktor Penyebab Kerusakan Dini Perkerasan Jalan Lentur dan Pengaruhnya Terhadap Biaya Penangan. *Jurnal Infrastruktur*, 3.
- Pothuganti, S. (2018). Review on Over-fitting and Under-fitting Problems in Machine Learning and Solutions. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 7(9), 3692–3695.
<https://doi.org/10.15662/IJAREEIE.2018.0709015>
- Ratnawati, D., Huda, M., & Priyoto. (2018). Preliminary Cost Estimate Model for Maintenance and Improvement of Road Project. *The International Journal of Engineering and Science (IJES)*, 7(2), 41–49.
<https://doi.org/10.9790/1813-0702014149>
- Roring, H. S. D., Sompie, B. F., & Mandagi, R. J. M. (2014). Model Estimasi Biaya Tahap Konseptual Konstruksi Bangunan Gedung dengan Metode Parametrik. *Jurnal Ilmiah Media Engineering, Universitas Sam Ratulangi*, 4(2), 103–108.

- Roxas, C. L. C., Roxas, N. R., Cristobal, J., Hao, S. E., Marie Rabino, R., & Revalde, F. (2019). Modeling Road Construction Project Cost in the Philippines Using the Artificial Neural Network Approach. *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2019*. doi : 10.1109/HNICEM48295.2019.9072820
- Sari, F. A. K., & Latief, Y. (2021). Safety Cost Estimation of Building Construction with Fuzzy Logic and Artificial Neural Network. *Journal of Physics: Conference Series*, 1803(1).
<https://doi.org/10.1088/1742-6596/1803/1/012020>
- Shrestha, K. K., & Shrestha, P. P. (2016). A Contingency Cost Estimation System for Road Maintenance Contracts. *Procedia Engineering*, 145(December), 128–135.
<https://doi.org/10.1016/j.proeng.2016.04.030>
- Tadesse, N., & Dinku, A. (2017). Conceptual Cost Estimation of Road Projects in Ethiopia Using Neural Networks. *Journal of EEA*, 35.
- Tahapari, Y. (2021). *Tesis Analisis Perkiraan Biaya Pelaksanaan Proyek Peningkatan Jalan Aspal Berdasarkan Metode CSM Dan ANN (Studi Kasus: Proyek Peningkatan Jalan Aspal di Provinsi D.I Yogyakarta)*. Universitas Gadjah Mada.
- Tijanić, K., Car-Pušić, D., & Šperac, M. (2020). Cost Estimation in Road Construction Using Artificial Neural Network. *Neural Computing and Applications*, 32(13), 9343–9355.
<https://doi.org/10.1007/s00521-019-04443-y>
- Winalytra, I., Nugroho, A. S. B., & Triwiyono, A. (2018). Cost Estimation Model for I-Girder Bridge Superstructure Using Multiple Linear Regression and Artificial Neural Network. *Applied Mechanics and Materials*, 881, 142–149.
<https://doi.org/10.4028/www.scientific.net/amm.881.142>



© 2023 Siklus Jurnal Teknik Sipil All rights reserved. This is an open access article distributed under the terms of the CC BY Licens (<http://creativecommons.org/licenses/by/4.0/>)