

## PENERAPAN JARINGAN SYARAF TIRUAN UNTUK PREDIKSI BIAYA PROYEK KONTRUKSI JALAN MENGGUNAKAN METODE BACKPROPAGATION DENGAN MODEL MLP (STUDI KASUS : JALAN WILAYAH KABUPATEN PEKALONGAN)

Andika Syahrul Firdan<sup>1\*</sup>, Dedy Kurniadi<sup>2</sup>

<sup>1,2</sup> Teknik Informatika, Fakultas Teknologi Industri, Univeritas Islam Sultan Agung Semarang, Indonesia

<sup>1</sup>[andikasyahrul016@std.unissula.ac.id](mailto:andikasyahrul016@std.unissula.ac.id)

<sup>2</sup>[ddy.kurniadi@unissula.ac.id](mailto:ddy.kurniadi@unissula.ac.id)

Received: 10-07- 2025

Revised: 20-07-2025

Approved: 25-07-2025

### ABSTRACT

Penelitian ini bertujuan untuk mengembangkan sistem prediksi harga satuan dan estimasi biaya proyek jalan berbasis web menggunakan model Artificial Neural Network (ANN) dengan arsitektur Multilayer Perceptron (MLP) dan algoritma backpropagation untuk menghasilkan hasil prediksi berupa harga satuan dan estimasi total biaya. Model dilatih dengan data historis harga satuan empat jenis pekerjaan jalan—Lapis Pondasi Agregat, Pelaburan Keras, Agregat Penutup Burda, dan Latasir Manual—dari tahun 2017 hingga 2024. Data diproses melalui tahapan cleaning, transformasi ke long format, encoding, dan normalisasi. Proses pelatihan menggunakan 300 epoch dengan batch size 32 dan validasi 20% dari data pelatihan. Hasil evaluasi menunjukkan performa model yang sangat baik dengan nilai Mean Squared Error (MSE) sebesar 598.031.344,79, Mean Absolute Error (MAE) sebesar 12.923,91, Mean Absolute Percentage Error (MAPE) sebesar 24,68%, serta koefisien determinasi ( $R^2$ ) sebesar 0,9818. Hasil penelitian berupa grafik Scatter plot dan histogram distribusi prediksi juga menunjukkan kedekatan yang konsisten antara nilai aktual dan prediksi. Dengan performa tersebut, model ANN terbukti mampu melakukan prediksi harga satuan yang akurat. Sistem ini kemudian diimplementasikan dalam bentuk aplikasi web menggunakan Streamlit, yang memungkinkan pengguna untuk memasukkan parameter (tahun, dimensi jalan, dan PPN) kemudian memperoleh hasil prediksi harga satuan serta estimasi total biaya proyek secara otomatis sehingga dapat digunakan untuk membantu pengambilan keputusan dalam perencanaan anggaran proyek konstruksi jalan.

Kata kunci : ANN, Prediksi, Evaluai, Estimasi, Streamlit.

### PENDAHULUAN

Industri konstruksi memiliki peran penting dalam mendorong pertumbuhan ekonomi suatu negara. Dalam penelitian [1] indonesia memberikan lebih dari 67% kontribusi terhadap pasar konstruksi asean dan keuntungan yang bisa di dapat jasa konstruksi menjadi yang tertinggi di asean. Selain memberi keuntungan untuk kontraktor, pembangunan juga membuka lapangan perkerjaan untuk penduduk tetap karena bisa menyerap tenaga kerja di tempat proyek berlangsung.

Salah satu tantangan kontraktor dan pemilik proyek adalah bagaimana mengetahui harga material, sewa alat, pekerja di tahun depan. Untuk mengetahui hal tersebut dinilai penting karena harga satuan pekerjaan seperti harga material, sewa alat, upah pekerja akan meningkat atau menurun seiring bertambahnya tahun karena pengaruh inflasi, kebijakan pemerintah, dan dinamika pasar. Senada dengan penelitian [2] yang juga berpendapat, indeks biaya konstruksi (Construction Cost Index) sangat dipengaruhi oleh faktor eksternal seperti inflasi, harga material, dan kondisi pasar. Selain memprediksi harga satuan pekerjaan, pemilik proyek dan kontraktor juga perlu mempertimbangkan variabel panjang, lebar, ketebalan pada jalan yang akan dibuat dan PPN pada tahun yang ingin di prediksi.

Dari permasalahan tersebut maka perlu adanya sistem prediksi dan estimasi biaya. Sistem prediksi adalah metode komputasi yang menggunakan algoritma pembelajaran mesin (seperti ANN) untuk memperkirakan nilai masa depan berdasarkan pola historis data. Sistem ini menganalisis data input, mempelajari hubungan antar variabel, dan menghasilkan output prediksi yang digunakan sebagai dasar pengambilan keputusan [3]. Kemudian perkiraan biaya atau estimasi biaya adalah seni memperkirakan (the art of approximating) jumlah biaya yang diperlukan untuk suatu kegiatan yang didasarkan atas informasi yang tersedia pada waktu tertentu [4]. Dalam pengertian kegiatan estimasi biaya di konstruksi adalah merupakan salah satu langkah penting dalam proyek konstruksi yang bertujuan untuk menentukan jumlah dana yang perlu disiapkan untuk peningkatan atau rehabilitasi sebuah jalan. Estimasi biaya ini dapat dikembangkan menggunakan jaringan syaraf tiruan dengan memanfaatkan algoritma pembelajaran

mesin dan sistem ini dapat belajar dari pola-pola yang ada kemudian akan menghasilkan estimasi biaya berdasarkan data proyek peningkatan jalan sebelumnya.

Jaringan syaraf tiruan (JST) dalam sistem komputer berperan sebagai pengolah informasi yang karakteristik nya mirip dengan jaringan syaraf biologis saat menerima dan memproses informasi dari dunia luar. Menurut [5] dalam praktiknya, jaringan syaraf tiruan sangat efektif dalam menangani masalah klasifikasi dan situasi yang toleran terhadap ketidakpastian, terutama ketika tersedia banyak data pelatihan, tetapi dengan aturan yang tidak selalu mudah diterapkan. Maksudnya ialah keunggulan Jaringan Syaraf Tiruan (JST) terletak pada kemampuannya mempelajari pola data tanpa memerlukan aturan yang rumit. Kemudian menurut [6] , model matematika yang dihasilkan dari jaringan syaraf tiruan sangat berguna dan memberikan manfaat yang baik dalam membuat estimasi biaya proyek pada tahap konseptual, karena informasi yang diperlukan dapat diekstraksi dengan mudah dari sketsa atau definisi lingkup proyek. Salah satu keunggulan dibandingkan dengan metode model tradisional atau manual, terutama dalam konteks estimasi biaya terletak pada tingkat akurasi.

Dalam upaya meningkatkan akurasi, penelitian ini memilih untuk mengimplementasikan arsitektur backpropagation dalam jaringan syaraf tiruan pada sistem estimasi biaya proyek peningkatan jalan. Backpropagation merupakan algoritma dalam pelatihan jaringan saraf tiruan, yang bertujuan untuk meningkatkan akurasi estimasi dari model. Proses ini terbagi menjadi dua fase yaitu fase forward pass, di mana data input diolah untuk menghasilkan output dan menghitung kesalahan, serta fase backward pass, yang berfungsi untuk menghitung gradien dari fungsi kerugian guna memperbarui bobot jaringan sesuai dengan kesalahan yang terdeteksi. Backpropagation bekerja melalui proses secara iteratif dengan menggunakan sekumpulan contoh data (data training), membandingkan nilai produksi dari jaringan dengan setiap contoh data [7]. Dalam sistem estimasi biaya proyek peningkatan jalan, backpropagation berkontribusi pada peningkatan akurasi estimasi biaya dengan memanfaatkan data proyek sebelumnya.

Beberapa penelitian sebelumnya yang menggunakan metode ann menunjukkan hasil yang positif, yang pertama pada penelitian yang dilakukan oleh Yoszy Aldo Tondayana dan Doddy Prayogo yang mengeksplorasi penerapan metode Artificial Neural Network (ANN) untuk dibandingkan dengan metode regresi linier dalam memprediksi biaya konstruksi. Model ANN mencatat nilai Mean Absolute Percentage Error (MAPE) sebesar 15.23%, sedangkan regresi linier mencapai 18.74%. Dengan nilai

R sebesar 0.68 untuk ANN dan 0.47 untuk regresi linier, ANN terbukti lebih akurat dalam menangkap hubungan kompleks antar variabel [8]. Yang kedua dari penelitian yang berjudul “Estimasi Biaya Struktur Gedung Rumah Sakit Dengan Bentuk Persegi Panjang Menggunakan Metode Artificial Neural Network” dengan model ANN yang dibangun menunjukkan sensitivitas yang tinggi terhadap dimensi balok dan kolom. Hasil simulasi menghasilkan persentase error (MMRE) yang cukup kecil, yakni  $\pm 1,55\%$  pada data pelatihan dan  $\pm 9,75\%$  pada data uji random [9]. Yang ketiga pada penelitian yang berjudul “*Development and application of a hybrid artificial neural network model for simulating future stream flows in catchments with limited in situ observed data*” yang mengembangkan model ANN feed-forward (Multilayer Perceptron) menggunakan Python 3.11 untuk memprediksi aliran sungai. Prosesnya meliputi penentuan arsitektur jaringan, normalisasi data, serta pelatihan dengan algoritma backpropagation dan evaluasi menggunakan MSE—sebagai metode yang efektif untuk memodelkan hubungan non-linear pada data hidrologi[10].

Sebelum melatih data alangkah pentingnya untuk memproses data atau biasa disebut *preprocessing data*. Penelitian ini melakukan beberapa tahap preprocessing data untuk memastikan data siap dilatih dan untuk membantu ke-akuratan hasil prediksi, salah satunya dengan normalisasi data. Pada penelitian yang berjudul “*The choice of scaling technique matters for classification performance*”, penelitian ini menguji lima metode scaling (termasuk normalisasi) terhadap 20 algoritma klasifikasi menggunakan 82 dataset publik. Hasilnya menunjukkan bahwa pemilihan teknik scaling yang tepat secara signifikan memengaruhi akurasi model – terkadang lebih penting daripada pemrosesan data itu sendiri[11]. Yang kedua pada penelitian yang berjudul “*Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques*”, penelitian ini menunjukkan bahwa untuk data multivariat, teknik normalisasi (Min-Max dan Z-Score) sangat mempengaruhi hasil model LSTM, karena membantu menyeimbangkan skala fitur yang berbeda-beda[12].

Kemudian untuk pelatihan data menggunakan algoritma backpropagation sebagai metode pelatihan yang berdasarkan penelitian sebelumnya juga menghasilkan hasil yang sesuai seperti pada penelitian Pragma dkk yang menerapkan backpropagation untuk memprediksi rata-rata harga beras bulanan. Hasilnya menunjukkan bahwa model mampu mempelajari fluktuasi harga dengan baik, dengan error prediksi yang dapat ditekan melalui proses pelatihan iteratif menggunakan learning rate dan epoch yang sesuai[13]. Yang kedua dari penelitian yang berjudul “*Improving the Backpropagation Algorithm with Consequentialism Weight Updates over Mini-Batches*” penelitian ini mengembangkan varian backpropagation dengan pembaruan bobot secara konsekuensial pada mini-batch. Teknik ini terbukti meningkatkan stabilitas dan kecepatan konvergensi model, sehingga lebih efisien dibanding pelatihan standar[14]. Yang ketiga pada penelitian yang berjudul “*Implementasi Backpropagation ANN dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi*”, backpropagation dikombinasikan dengan algoritma genetika untuk estimasi pendapatan perusahaan ekspedisi. Model ANN dengan struktur 4-10-1 berhasil mencapai MSE yang rendah setelah 487 epoch, menegaskan efektivitas backpropagation dalam problem bisnis riil [15].

Selanjutnya model yang digunakan dalam pelatihan ini adalah model MLP, dari beberapa referensi yang bisa dijadikan tolak ukur ke-akuratan model ini untuk prediksi. Contohnya pada penelitian yang berjudul “*Machine learning multilayer*

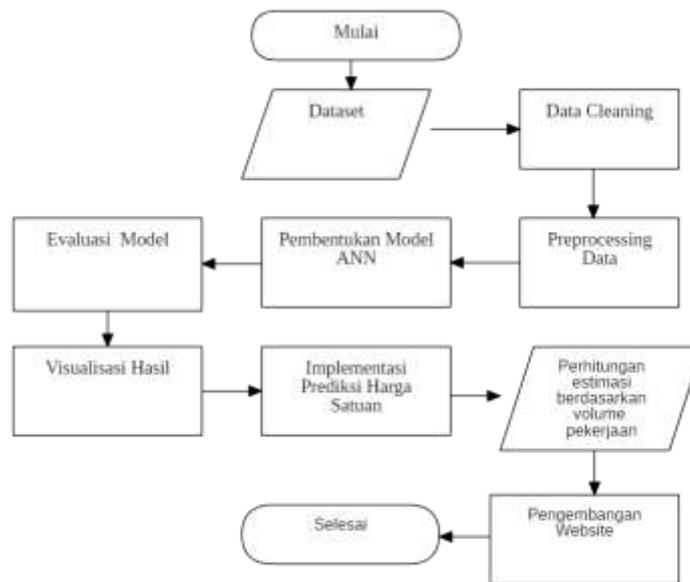
*perceptron method for building information modeling application in engineering performance prediction*" di penelitian tersebut mereka mengembangkan model MLP untuk mengkorelasikan penggunaan BIM terhadap kinerja proyek konstruksi, menghasilkan prediksi yang akurat pada sampel data terbatas ~60 sampel [16]. Yang kedua pada penelitian yang berjudul "Multilayer perceptron-based self-care early prediction of children with disabilities (Digital Health)", studi ini menggunakan MLP untuk prediksi dini dalam konteks kesehatan, menunjukkan MLP cocok diterapkan pada domain data numerik dan klasifikasi sensitif [17]. Yang ketiga pada studi yang berjudul "Back to Basics : The Power of the Multilayer Perceptron in Financial Time Series Forecasting" yang membandingkan MLP, LSTM, dan Transformer dalam forecasting nilai ekonomi. Hasilnya menunjukkan MLP sebagai model sederhana namun efektif untuk univariate time series, seringkali lebih unggul dibanding model yang lebih kompleks memberikan dasar kuat penggunaan MLP untuk data harga satuan [18].

Dalam ini penelitian menggunakan evaluasi model prediksi regresi yaitu MSE, MAE, MAPE, dan koefisien determinasi ( $R^2$ ) karena output nya berupa nilai *continuu*, beberapa penelitian telah menggunakan evaluasi model ini. Contoh pada studi yang berjudul "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation", studi ini menegaskan bahwa walaupun MSE, MAE, dan MAPE sering digunakan, akan tetapi jika menambahkan koefisien determinasi ( $R^2$ ) pada tahap evaluasi tentu akan memberikan informasi lebih kaya dalam mengevaluasi performa model regresi, karena mampu menunjukkan seberapa besar variabilitas data dapat dijelaskan oleh model [19]. Yang kedua pada penelitian dengan judul "Comparative Evaluation of Model Accuracy for Predicting Selected Attributes in Agile Project Management" penelitian tersebut membandingkan beberapa jenis model (CNN, LSTM, MLP, RNN, GRU) menggunakan metrik MAE, MSE, dan MAPE. Hasil menunjukkan MLP memiliki MAE 0.016 dan MSE sangat kecil, yang menggambarkan efektivitas evaluasi regresi menggunakan kombinasi metrik dasar [20].

Untuk menampilkan hasil visual prediksi dan estimasi, pada penelitian ini menggunakan streamlit yaitu framework dari python untuk menampilkan hasil / output prediksi dan estimasi dalam bentuk web yang *friendly*, sehingga siap digunakan user.

Penelitian ini bertujuan untuk mengimplementasikan sistem prediksi harga satuan serta estimasi biaya konstruksi jalan menggunakan jaringan syaraf tiruan menggunakan pelatihan backpropagation model *multilayer perceptron* (MLP) untuk memprediksi harga satuan pekerjaan jalan serta mengimplementasikan sistem berbasis web menggunakan framework streamlit untuk menghitung estimasi biaya dari input panjang, lebar, ketebalan serta total perhitungannya. Sistem ini diharapkan dapat memberikan dukungan dalam pengambilan keputusan bagi pemilik proyek dengan memprediksi harga satuan untuk tahun-tahun mendatang, serta mengestimasi total biaya proyek. Dengan demikian, sistem ini dapat digunakan sebagai acuan awal dalam proses perencanaan dan penyusunan anggaran proyek pembangunan jalan.

## METODE PENELITIAN



Gambar 2. 1 Flowchart metode penelitian

1. Dataset

Pengumpulan data dilakukan dengan memperoleh data dari dokumen Rencana Anggaran Biaya (RAB) dan HSP atau harga satuan pekerjaan dari Dinas Pekerjaan Umum Kabupaten Pekalongan. Entri dalam dataset mencakup informasi tentang tahun, jenis pekerjaan (seperti LPA, pelaburan, burda, latasir manual), dan harga satuan masing-masing jenis pekerjaan. Data tersebut diperoleh melalui wawancara dengan pemilik perusahaan CV Binarekatama. Jumlah data yang digunakan dalam penelitian ini adalah 64 entri dengan 5 kolom.

Tabel 2. 1 Dataset mentah

Tahun	LPA (m <sup>3</sup> )	Pelaburan (Ltr)	Burda (m <sup>2</sup> )	Latasir (m <sup>2</sup> )
2017	Rp 345,879.47	Rp 9,532.62	Rp 30,093.02	Rp 61,720.08
2018	Rp 339,256.78	Rp 10,230.03	Rp 30,816.47	Rp 65,455.98
2019	Rp 348,744.24	Rp 11,492.94	Rp 32,673.11	Rp 72,690.34
2020	Rp 343,577.49	Rp 11,685.36	Rp 33,995.95	Rp 79,708.50
2021	Rp 365,547.28	Rp 11,429.83	Rp 27,338.78	Rp 77,086.25
2022	Rp 433,294.13	Rp 14,318.43	Rp 32,498.75	Rp 105,551.69
2023	Rp 490,267.11	Rp 15,802.17	Rp 33,870.81	Rp 101,304.44
2024	Rp 472,737.98	Rp 13,629.69	Rp 35,118.78	Rp 90,521.27

2. Data Cleaning

```
#mengubah tabel ke long format dan menghapus data kosong
df_long = df.melt(id_vars=['Tahun'], var_name='Jenis Pekerjaan', value_name='Harga Satuan')
df_long.dropna(inplace=True)
df_long.reset_index(drop=True, inplace=True)
df_long.head()
```

Gambar 2. 2 menghapus data kosong

Pada gambar 2.2 terlihat saya menebalkan skrip `df_long.dropna(inplace=True)` yang skrip tersebut berfungsi untuk menghapus data kosong agar saat tidak error atau hilang saat data sedang diproses.

### 3. Preprocessing Data

#### a) Mengubah tabel ke *long* format

```
#mengubah tabel ke long format dan menghapus data kosong
df_long = df.melt(id_vars=['Tahun'], var_name='Jenis_Pekerjaan', value_name='Harga_Satuan')
df_long.dropna(inplace=True)
df_long.reset_index(drop=True, inplace=True)
df_long.head()
```

Gambar 2. 3 ubah tabel ke long format

Pada gambar 2.3 merupakan skrip untuk mengubah tabel ke long format yang berfungsi agar variabel x dan y terdefinisi dengan jelas. Variabel x adalah tahun dan jenis\_pekerjaan kemudian variabel y adalah harga\_satuan.

```
df_long.head()
```

	Tahun	Jenis_Pekerjaan	Harga_Satuan
0	2017	LPA	345,879.47
1	2018	LPA	339,256.78
2	2019	LPA	348,744.24
3	2020	LPA	343,577.49
4	2021	LPA	365,547.28

Gambar 2. 4 Hasil ubah tabel ke long format

Gambar 2.4 menunjukkan hasil dari perubahan tabel wide ke long format.

#### b) Mengurutkan kolom tabel

```
mengurutkan kolom tabel sesuai dengan dataset awal
urutan_pekerjaan = ['LPA', 'Pelaburan Keras', 'Burda', 'Latasir Manual']
df_long['Jenis_Pekerjaan'] = pd.Categorical(df_long['Jenis_Pekerjaan'], categories=urutan_pekerjaan, ordered=True)
df_long = df_long.sort_values(by=['Tahun', 'Jenis_Pekerjaan']).reset_index(drop=True)
```

Gambar 2. 5 skrip mengurutkan kolom tabel

Pada gambar 2.5 merupakan skrip untuk mengurutkan kolom tabel yang berfungsi untuk menjaga keteraturan data, baik untuk keperluan visualisasi, pelaporan, maupun pemrosesan serta mencegah kesalahan interpretasi model akibat urutan kategori yang berubah-ubah.

```
df_long.head()
```

	Tahun	Jenis_Pekerjaan	Harga_Satuan
0	2017	LPA	345,879.47
1	2017	Pelaburan Keras	9,532.62
2	2017	Burda	30,093.02
3	2017	Latasir Manual	61,720.08
4	2018	LPA	339,256.78

Gambar 2. 6 Hasil mengurutkan tabel

Gambar 2.6 menunjukkan hasil dari perintah untuk mengurutkan tabel

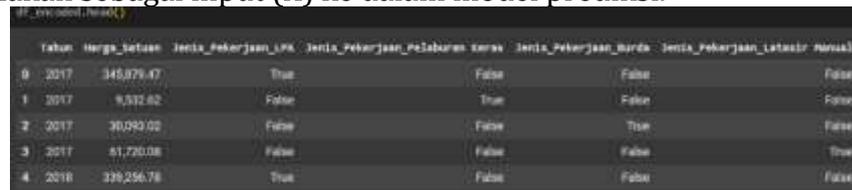
sehingga bisa di proses ke tahap selanjutnya.

c) One-hot encoding

```
#mengubah kolom jenis pekerjaan ke one hot encoding
df_encoded = pd.get_dummies(df_long, columns=['Jenis Pekerjaan'])
```

Gambar 2. 7 Encoding kolom jenis pekerjaan

Pada gambar 2.7 merupakan skrip untuk mengubah kolom jenis pekerjaan ke one hot encoding, yaitu kolom-kolom biner untuk setiap jenis pekerjaan. Hasilnya adalah DataFrame baru (df\_encoded) yang siap digunakan sebagai input (X) ke dalam model prediksi.



	Tahun	Harga_Satuan	Jenis_Pekerjaan_LPA	Jenis_Pekerjaan_Pelaburan_keras	Jenis_Pekerjaan_Burda	Jenis_Pekerjaan_Lataair	Manual
0	2017	345,079.47	True	False	False	False	False
1	2017	9,312.62	False	True	False	False	False
2	2017	30,092.02	False	False	True	False	False
3	2017	81,720.08	False	False	False	True	True
4	2018	339,256.78	True	False	False	False	False

Gambar 2. 8 Hasil encoding kolom jenis pekerjaan

Gambar 2.8 menunjukkan hasil perintah untuk encoding kolom jenis pekerjaan berupa tabel yang ditampilkan 5 teratas

d) Normalisasi kolom tahun dan harga satuan

```
menormalisasi kolom tahun dan harga satuan
scaler_tahun = MinMaxScaler()
scaler_harga = MinMaxScaler()

df_encoded['tahun'] = scaler_tahun.fit_transform(df_encoded[['tahun']])
df_encoded['harga_satuan'] = scaler_harga.fit_transform(df_encoded[['harga_satuan']])

joblib.dump(scaler_tahun, 'scaler_tahun.pkl')
joblib.dump(scaler_harga, 'scaler_harga.pkl')
```

Gambar 2. 9 Normalisasi kolom tahun dan harga satuan

Pada Gambar 2.9, skrip scaler\_tahun = MinMaxScaler() dan scaler\_harga = MinMaxScaler() digunakan untuk membuat objek normalisasi Min-Max pada kolom Tahun dan Harga\_Satuan, dengan tujuan mengubah nilai numerik ke rentang 0–1 agar pelatihan model lebih stabil. Proses normalisasi dilakukan menggunakan fit\_transform, dan objek scaler disimpan dalam format .pkl untuk digunakan kembali saat prediksi di antarmuka web.



	Tahun	Harga_Satuan	Jenis_Pekerjaan_LPA	Jenis_Pekerjaan_Pelaburan_keras	Jenis_Pekerjaan_Burda	Jenis_Pekerjaan_Lataair	Manual
0	0.00	0.70	True	False	False	False	False
1	0.00	0.00	False	True	False	False	False
2	0.00	0.04	False	False	True	False	False
3	0.00	0.11	False	False	False	True	True
4	0.14	0.88	True	False	False	False	False

Gambar 2. 10 Hasil normalisasi kolom tahun dan harga satuan

Gambar 2.10 menunjukkan hasil normalisasi kolom tahun dan harga satuan yang siap digunakan sebagai input ke model *Artificial Neural Network* (ANN)

e) Membagi data latihan dan uji

```
#membagi data train dan test
X_all = df_encoded.drop(columns=['Harga_Satuan']) # Semua fitur termasuk tahun
y_all = df_encoded['Harga_Satuan']
X_train, X_test, y_train, y_test, tahun_train, tahun_test = train_test_split(
    X_all, y_all, tahun_all, test_size=0.2, random_state=42
)
```

Gambar 2. 11 Membagi data pelatihan dan uji

Gambar 2.11 menunjukkan skrip pemisahan data menjadi data pelatihan dan pengujian menggunakan train\_test\_split, dengan X\_all

sebagai fitur, `y_all` sebagai target, dan `tahun_all` untuk keperluan visualisasi. Tujuannya adalah memastikan pelatihan dan evaluasi model dilakukan secara seimbang.

#### 4. Pelatihan Model

```
#pelatihan model
history = model.fit(X_train, y_train, validation_split=0.2, epochs=300, batch_size=32, verbose=0)
```

Gambar 2. 12 Pelatihan model

Gambar 2.12 menampilkan skrip pelatihan model dengan `model.fit()`, menggunakan `X_train` dan `y_train` selama 300 epoch. Sebanyak 20% data digunakan sebagai validasi (`validation_split=0.2`), dan pelatihan dibagi dalam mini-batch berukuran 32 untuk efisiensi. Proses ini disimpan dalam variabel `history` untuk analisis perkembangan nilai loss, sementara `verbose=0` menonaktifkan output log.

#### 5. Evaluasi Model

```
#prediksi
y_pred = model.predict(X_test)

#denormalisasi kolom
y_pred_denorm = scaler_harga.inverse_transform(y_pred).flatten()
y_test_denorm = scaler_harga.inverse_transform(y_test.values.reshape(-1, 1)).flatten()
#tahun_denorm = scaler_tahun.inverse_transform(X_test[['tahun']])

#evaluasi model
mse = mean_squared_error(y_test_denorm, y_pred_denorm)
mae = mean_absolute_error(y_test_denorm, y_pred_denorm)
mape = np.mean(np.abs((y_test_denorm - y_pred_denorm) / y_test_denorm)) * 100
r2 = r2_score(y_test_denorm, y_pred_denorm)

#menampilkan hasil evaluasi model
print(f"MSE : {mse:.2f}")
print(f"MAE : {mae:.2f}")
print(f"MAPE : {mape:.2f}%")
print(f"R2 : {r2:.4f}")
```

Gambar 2. 13 Denormalisasi dan Evaluasi model

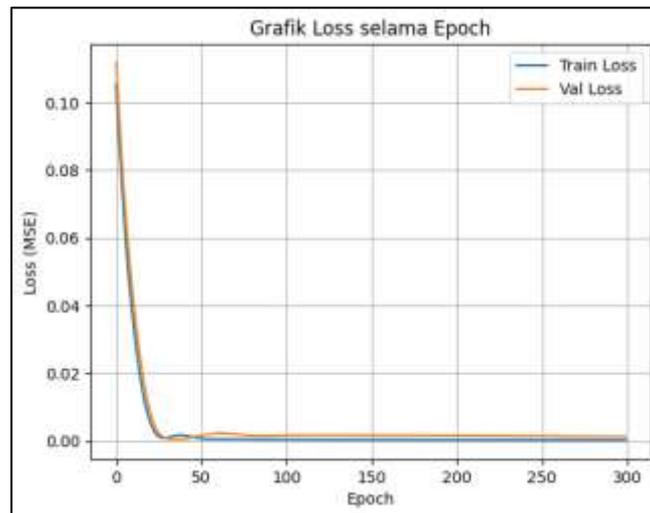
Gambar 2.13 menunjukkan proses prediksi dan evaluasi model. Setelah `model.predict(X_test)` menghasilkan output ter-normalisasi, nilai prediksi dan aktual dikembalikan ke skala asli dengan `inverse_transform()`. Selanjutnya, performa model dievaluasi menggunakan metrik MSE, MAE, MAPE, dan  $R^2$ .

```
MSE : 598031344.79
MAE : 12923.91
MAPE : 24.68%
R2 : 0.9818
```

Gambar 2. 14 Hasil evaluasi model

Hasil evaluasi pada gambar 2.14 menunjukkan bahwa model ANN memiliki performa prediksi yang baik. MSE sebesar 598 juta dan MAE sebesar Rp12.923,91 menunjukkan kesalahan prediksi yang relatif rendah dibandingkan skala harga satuan. MAPE sebesar 24,68% menunjukkan model masih bisa ditingkatkan, terutama untuk harga ekstrem. Namun, nilai  $R^2$  sebesar 0,9818 menandakan model mampu menjelaskan 98,18% variasi data dengan baik.

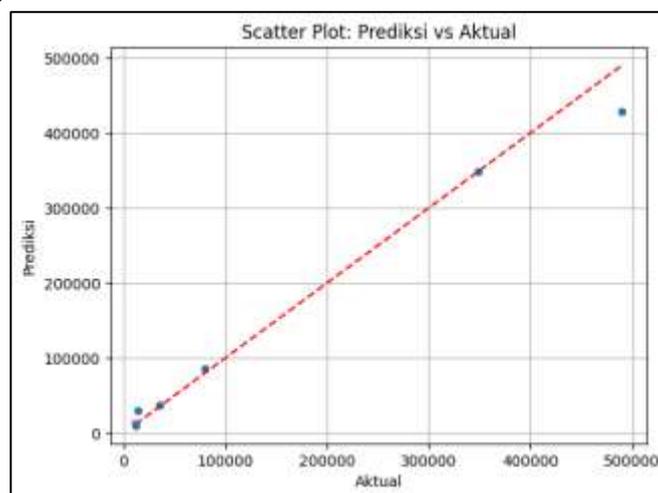
1. Visualiasi Hasil Pelatihan Model (analisa performa model)
  - a) Grafik loss



Gambar 3. 1 Grafik loss selama Epoch

Gambar 3.1 menunjukkan grafik loss (MSE) pada data pelatihan dan validasi selama 300 epoch. Terlihat penurunan signifikan di awal pelatihan dan stabil mendekati nol setelah epoch ke-30, tanpa indikasi overfitting atau underfitting. Kurva yang sejajar menunjukkan model belajar secara seimbang. Grafik ini mendukung hasil evaluasi kuantitatif seperti MSE dan  $R^2$ , sekaligus membuktikan bahwa parameter pelatihan telah dipilih dengan tepat.

- b) Scatter Plot



Gambar 3. 2 Scatter plot

Gambar 3.2 menampilkan scatter plot antara nilai aktual (x) dan prediksi model (y), dengan garis merah putus-putus sebagai acuan ideal ( $y = x$ ). Sebagian besar titik berada dekat garis, menunjukkan prediksi model cukup akurat. Meski terdapat sedikit deviasi pada nilai tinggi, kesalahan masih dalam batas wajar. Grafik ini memperkuat hasil evaluasi seperti  $R^2$  tinggi dan MSE rendah, serta menunjukkan bahwa model ANN memiliki kemampuan prediksi yang baik untuk estimasi harga satuan konstruksi jalan.

2. Hasil Sistem

a) Input parameter panjang, lebar, ketebalan, PPN



Gambar 3. 3 Tampilan input

Gambar 3.3 menampilkan antarmuka utama sistem berbasis web yang dirancang interaktif dan mudah digunakan. Pengguna menginputkan tahun prediksi, dimensi jalan (panjang, lebar, ketebalan), serta persentase PPN melalui input numerik dan slider. Tahun akan dinormalisasi dan digunakan oleh model ANN untuk memprediksi harga satuan. Dimensi digunakan untuk menghitung volume pekerjaan, dan PPN ditambahkan ke total estimasi. Proses dihitung setelah tombol "Prediksi dan Hitung Estimasi" ditekan, menghasilkan estimasi biaya proyek secara otomatis.

b) Output / hasil prediksi dan estimasi

	Jenis Pekerjaan	Satuan	Volume	Harga Satuan	Jumlah Harga
0	LPA	m <sup>3</sup>	50.00	Rp 460,584.48	Rp 23,029,223.99
1	Pelaburan Keras	litr	1,250.00	Rp 61,272.52	Rp 76,590,652.54
2	Burda	m <sup>3</sup>	500.00	Rp 41,116.85	Rp 20,558,425.94
3	Latasir Manual	m <sup>3</sup>	500.00	Rp 102,417.27	Rp 51,208,633.86
4					
5				Total Harga	Rp 171,386,936.34
6				PPN (11%)	Rp 18,852,563.00
7				Total Setelah PPN	Rp 190,239,499.34
8				Dibulatkan	Rp 190,239,400.00

Gambar 3. 4 hasil estimasi dan perhitungan total

Gambar 3.4 menampilkan tabel hasil prediksi dan estimasi biaya berdasarkan empat jenis pekerjaan: LPA, Pelaburan Keras, Burda, dan Latasir. Masing-masing baris mencakup satuan, volume (dihitung dari

dimensi jalan), harga satuan (hasil prediksi model), dan jumlah harga (volume × harga satuan). Di bagian bawah tabel terdapat rekapitulasi: total harga sebelum pajak sebesar Rp. 171.386.936,34, PPN 11% sebesar Rp. 18.852.563,00, total setelah pajak Rp. 190.239.499,34, dan nilai akhir dibulatkan ke Rp. 190.239.400,00.

## KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem prediksi harga satuan dan estimasi biaya proyek peningkatan jalan berbasis web dengan memanfaatkan model *Artificial Neural Network* (ANN). Model dilatih menggunakan data historis dari tahun 2017 hingga 2024 yang mencakup empat jenis pekerjaan utama, yaitu Lapis Pondasi Agregat, Pelaburan Keras, Burda, dan Latasir Manual. Berdasarkan hasil evaluasi, model menunjukkan performa dengan nilai MSE sebesar 598.031.344,79, MAE sebesar 12.923,91, MAPE sebesar 24,68%, dan  $R^2$  sebesar 0,9818. Sistem dikembangkan menggunakan platform Streamlit sehingga pengguna dapat memasukkan parameter seperti tahun prediksi, panjang, lebar, dan ketebalan jalan, lalu memperoleh estimasi biaya secara otomatis, cepat, dan transparan. Namun, masih terdapat beberapa faktor yang mempengaruhi ketidakakuratan hasil prediksi, di antaranya adalah terbatasnya jumlah dan keragaman data, minimnya fitur *input* (hanya tahun), ketidakseimbangan skala harga antar jenis pekerjaan, *overfitting* pada tahun tertentu, distribusi data yang tidak merata, pengaruh nilai ekstrem (*outlier*), serta kemungkinan kesalahan dalam pencatatan data historis (label noise) juga dapat menyebabkan deviasi prediksi.

## DAFTAR PUSTAKA

- [1] C. Utomo *dkk.*, “Model Pelatihan Kelayakan Proyek Untuk UMKM Konstruksi dalam Pengembangan Usaha,” *Sewagati*, vol. 7, no. 3, hal. 405–411, 2023.
- [2] A. AlTalhoni, H. Liu, dan O. Abudayyeh, “Forecasting Construction Cost Indices: Methods, Trends, and Influential Factors,” *Buildings*, vol. 14, no. 10. 2024, doi: 10.3390/buildings14103272.
- [3] R. Nasution, “Pengembangan Sistem Prediksi Kegagalan Mesin Berbasis AI untuk Industri Manufaktur,” *J. Terap. Ilmu Pengetah.*, vol. 1, no. 1, hal. 47–51, 2024.
- [4] I. Soeharto, *Manajemen Proyek Dari Konseptual Sampai Operasional*. Jakarta: Erlangga, 1997.
- [5] L. A. ZAHIR dan M. MUHLIS, “JARINGAN SARAF TIRUAN (NEURAL NETWORK) UNTUK ESTIMASI PRODUKTIVITAS PEKERJA KONSTRUKSI,” *J. DAKTILITAS*, vol. 2, no. 2, hal. 142–153, 2022.
- [6] M. Ridwan, B. P. Sutardi, dan L. M. G. Jaya, “Rancang Bangun Aplikasi Perhitungan Rencana Anggaran Biaya (RAB) Pembangunan Rumah Tinggal,” *Ranc. Bangun Apl. Perhitungan Rencana Anggar. Biaya*, vol. 4, no. 1, hal. 57–64, 2018.
- [7] A. Bimantoro, S. Sumarno, dan H. S. Tambunan, “Estimasi Pemberantasan Hama di Kebun Bah Jambi Menggunakan Algoritma Backpropagation,” *J. Comput. Syst. Informatics*, vol. 2, no. 2, hal. 222–231, 2021.
- [8] Y. A. Tondayana dan D. Prayogo, “The Implementation of ANN in Predicting Construction Costs Considering Macroeconomic Factors: Penerapan Metode ANN Dalam Memprediksi Biaya Konstruksi Bangunan Dengan Mempertimbangkan Faktor Makroekonomi,” *Dimens. Utama Tek. Sipil*, vol. 11, no. 2, hal. 94–107, 2024.

- [9] R. Dewanti, A. Aminullah, dan H. Priyosulistyo, “Estimasi Biaya Struktur Gedung Rumah Sakit dengan Bentuk Persegi Panjang Menggunakan Metode Artificial Neural Network,” *J. Civ. Eng. Plan.*, vol. 2, no. 2, hal. 139–149, 2021.
- [10] S. N. Mugume, J. Murungi, P. M. Nyenje, J. I. Sempewo, J. Okedi, dan J. Sörensen, “Development and application of a hybrid artificial neural network model for simulating future stream flows in catchments with limited in situ observed data,” *J. Hydroinformatics*, vol. 26, no. 8, hal. 1944–1969, 2024.
- [11] L. B. V De Amorim, G. D. C. Cavalcanti, dan R. M. O. Cruz, “The choice of scaling technique matters for classification performance,” *Appl. Soft Comput.*, vol. 133, hal. 109924, 2023.
- [12] A. Pranolo *dkk.*, “Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques,” *Ilk. J. Ilm.*, vol. 16, no. 2, hal. 210–220, 2024.
- [13] D. A. Pragana, D. W. Manurung, dan A. P. Windarto, “Analisa Metode Backpropagation Pada Prediksi Rata-rata Harga Beras Bulanan Di Tingkat Penggilingan Menurut Kualitas,” *J. Comput. Informatics Res.*, vol. 2, no. 3, hal. 76–84, 2023.
- [14] N. Paeedeh dan K. Ghiasi-Shirazi, “Improving the backpropagation algorithm with consequentialism weight updates over mini-batches,” *Neurocomputing*, vol. 461, hal. 86–98, 2021.
- [15] A. Y. Naufal, M. Tafrikan, dan A. K. Rachmawati, “Implementasi Backpropagation ANN dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi Pengiriman Barang,” *Walisongo J. Inf. Technol.*, vol. 5, no. 1, hal. 65–78, 2023.
- [16] W.-B. Chiu dan L.-M. Chang, “Machine learning multilayer perceptron method for building information modeling application in engineering performance prediction,” *J. Chinese Inst. Eng.*, vol. 46, no. 7, hal. 713–725, 2023.
- [17] R. Ali, J. Hussain, dan S. W. Lee, “Multilayer perceptron-based self-care early prediction of children with disabilities,” *Digit. Heal.*, vol. 9, hal. 20552076231184056, 2023.
- [18] A. Lazcano, M. A. Jaramillo-Morán, dan J. E. Sandubete, “Back to basics: The power of the multilayer perceptron in financial time series forecasting,” *Mathematics*, vol. 12, no. 12, hal. 1920, 2024.
- [19] D. Chicco, M. J. Warrens, dan G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *Peerj Comput. Sci.*, vol. 7, hal. e623, 2021.
- [20] E. M. M. Alzeyani dan C. Szabó, “Comparative Evaluation of Model Accuracy for Predicting Selected Attributes in Agile Project Management,” *Mathematics*, vol. 12, no. 16, hal. 2529, 2024.