

**PENERAPAN JARINGAN SYARAF TIRUAN UNTUK
PREDIKSI BIAYA PROYEK KONSTRUKSI JALAN
MENGUNAKAN METODE BACKPROPAGATION DENGAN
MODEL MULTI LAYER PERCEPRON (STUDI KASUS :
JALAN WILAYAH KABUPATEN PEKALONGAN)**

LAPORAN TUGAS AKHIR

Proposal ini disusun guna untuk memenuhi salah satu syarat untuk menyelesaikan
Program Studi Teknik Informatika S-1 pada Fakultas Teknologi Industri
Universitas Islam Sultan Agung



DISUSUN OLEH:

**ANDIKA SYAHRUL FIRDAN
32602000014**

**FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG
2025**

FINAL PROJECT

**APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR
PREDICTING THE COST OF ROAD CONSTRUCTION
PROJECTS USING THE BACKPROPAGATION METHOD
WITH THE MLP MODEL (CASE STUDY: PEKALONGAN
DISTRICT ROADS)**

Proposed to complete the requirement to obtain a bachelor's degree
(S1) at Informatics Engineering Departement of Industrial Technology
Faculty Sultan Agung Islamic University



ARRANGED BY :

ANDIKA SYAHRUL FIRDAN
32602000014

**MAJORING OF INFORMATICS ENGINEERING
INDUSTRIAL TECHNOLOGY FACULTY
SULTAN AGUNG ISLAMIC UNIVERSITY
2025**

**LEMBAR PENGESAHAN
TUGAS AKHIR**


**PENERAPAN JARINGAN SYARAF TIRUAN UNTUK PREDIKSI BIAYA
PROYEK KONSTRUKSI JALAN MENGGUNAKAN METODE
BACKPROPAGATION DENGAN MODEL MULTI LAYER PERCEPTRON
(STUDI KASUS : JALAN WILAYAH KABUPATEN PEKALONGAN)**

**ANDIKA SYAHRUL FIRDAN
32602000014**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 23...~~Agustus~~...2025.


TIM PENGUJI UJIAN SARJANA :

Bagus Satrio WP, S.Kom. M.Cs.
NIDN. 1027118801
(Ketua Penguji)




(06-08-25)

Ir. Sri Mulyono, M.Eng.
NIDN. 0626066601
(Anggota Penguji)



06-08-25


Dedy Kurniadi S.Kom. M.Kom.
NIDN. 0622058802
(Pembimbing)




(06-08-25)

Semarang, 6...~~Agustus~~...2025

Mengetahui,
Kaprodi Teknik Informatika
Universitas Islam Sultan Agung



Moch Taufik, ST, MIT
NIDN. 0622037502



SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Andika Syahrul Firdan

NIM : 32602000014

Judul Tugas Akhir : PENERAPAN JARINGAN SYARAF TIRUAN UNTUK PREDIKSI
BIAYA PROYEK KONSTRUKSI JALAN MENGGUNAKAN
METODE BACKPROPAGATION DENGAN MODEL MULTI
LAYER PERCEPTRON (STUDI KASUS : JALAN WILAYAH
KABUPATEN PEKALONGAN)

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 6 Agustus 2025

Yang Menyatakan,



Andika Syahrul Firdan

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Andika Syahrul Firdan

NIM : 32602000014

Program Studi : Teknik Informatika

Fakultas : Teknologi Industri

Alamat Asal : Pekalongan, Jawa Tengah

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul Penerapan Jaringan Syaraf Tiruan Untuk Prediksi Biaya Proyek Konstruksi Jalan Menggunakan Metode Backpropagation Dengan Model Multi Layer Perceptron (Studi Kasus : Jalan Wilayah Kabupaten Pekalongan) Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmedjkan, dikelola dan pangkalan data dan dipublikasikan diinternet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 6 Agustus 2025

Yang menyatakan,



Andika Syahrul Firdan

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Allah SWT, yang telah memberikan rahmat, taufik serta hidayah-Nya, sehingga laporan Tugas Akhir ini dapat terselesaikan.

Tanpa lupa penulis mengucapkan terima kasih kepada :

1. Rektor UNISSULA Bapak Prof. Dr. H. Gunarto S.H., M.Hum yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Hj. Novi Marlyana, ST., MT., IPU.
3. Dosen pembimbing Bapak Deddy Kurniadi, S.T., M.Kom yang telah membimbing selama tugas akhir berlangsung.
4. Orang tua penulis yang telah mendukung dan mengizinkan untuk menyelesaikan laporan ini.
5. Dan kepada semua pihak yang tidak dapat saya sebutkan satu persatu.

Penulis menyadari bahwa dalam penyusunan laporan ini masih terdapat banyak kekurangan, untuk itu penulis mengharap kritik dan saran dari pembaca untuk sempurnanya laporan ini. Semoga dengan ditulisnya laporan ini dapat menjadi sumber ilmu bagi setiap pembaca.

Semarang, 7 Juli 2025

Andika Syahrul Firdan

DAFTAR ISI

LEMBAR PENGESAHAN TUGAS AKHIR.....	i
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	ii
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH.....	iii
KATA PENGANTAR.....	iv
DAFTAR ISI	v
DAFTAR GAMBAR.....	vii
DAFTAR TABEL	viii
ABSTRAK.....	ix
BAB I PENDAHULUAN.....	1
1.1 LATAR BELAKANG	1
1.2 PERUMUSAN MASALAH.....	3
1.3 PEMBATAHAN MASALAH.....	3
1.4 TUJUAN.....	3
1.5 MANFAAT.....	3
1.6 SISTEMATIKA PENULISAN.....	3
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	5
2.1 Tinjauan Pustaka.....	5
2.2 Dasar Teori.....	7
2.2.1 Metode Jaringan Syaraf Tiruan.....	7
2.2.2 Backpropagation.....	9
2.2.3 Multi Layer Perceptron (MLP).....	11
2.2.4 Python.....	12
2.2.5 Website.....	13
BAB III METODE PENELITIAN.....	15
3.1 Metodologi penelitian	15
3.1.1 Dataset.....	15
3.1.2 Data Cleaning.....	16
3.1.3 Preprocessing Data	16
3.1.4 Fitur Dan Target	19
3.1.5 Pelatihan Model.....	20
3.1.6 Evaluasi Model.....	21
3.1.7 Visualisasi Hasil	22
3.1.8 Implementasi Prediksi Harga Satuan	23
3.1.9 Perhitungan Estimasi Berdasarkan Volume Pekerjaan	23

3.1.10	Pengembangan Website	24
3.2	Software Yang Digunakan	24
3.3	Perancangan Sistem	26
BAB IV HASIL DAN ANALISIS PENELITIAN		28
4.1	Hasil dan Analisis	28
4.1.1	Data Cleaning	28
4.1.2	Data Preprocessing	28
4.1.3	Pelatihan Model.....	31
4.1.4	Evaluasi Model.....	32
4.2	Visualisasi Performa Model	37
4.2.1	Grafik Loss Selama Epoch	37
4.2.2	Scatter Plot	38
4.2.3	Histogram	39
4.2.4	Perbandingan Harga Satuan Aktual dan Prediksi per Tahun.....	40
4.2.5	Selisih Prediksi Terhadap Harga Aktual per Tahun.....	41
4.3	Deployment.....	42
4.3.1	Input Parameter Panjang, Lebar, Ketebalan, PPN.....	42
4.3.2	Tabel Hasil Prediksi dan Estimasi	43
4.3.3	Visualisasi Hasil Prediksi	46
BAB V KESIMPULAN DAN SARAN.....		48
5.1	Kesimpulan	48
5.2	Saran	48
DAFTAR PUSTAKA.....		49

DAFTAR GAMBAR

Gambar 4. 1 menghapus data kosong.....	28
Gambar 4. 2 Mengubah tabel ke long format	28
Gambar 4. 3 Menampilkan hasil long format	28
Gambar 4. 4 Mengurutkan kolom tabel.....	29
Gambar 4. 5 Hasil mengurutkan kolom tabel	29
Gambar 4. 6 Encoding kolom jenis pekerjaan	29
Gambar 4. 7 Hasil encoding kolom jenis pekerjaan	29
Gambar 4. 8 Normalisasi kolom tahun dan harga satuan	30
Gambar 4. 9 Hasil normalisasi kolom tahun dan harga satuan	30
Gambar 4. 10 Membagi data pelatihan dan uji	30
Gambar 4. 11 Membuat model ann	31
Gambar 4. 12 Pelatihan model	31
Gambar 4. 13 Denormalisasi dan Evaluasi model	32
Gambar 4. 14 Hasil evaluasi model.....	33
Gambar 4. 15 Grafik loss selama epoch	37
Gambar 4. 16 grafik scatter plot.....	38
Gambar 4. 17 grafik distribusi harga satuan	39
Gambar 4. 18 Perbandingan harga satuan aktuan dan prediksi	40
Gambar 4. 19 grafik selisih prediksi terhadap harga aktual	41
Gambar 4. 20 Tampilan input parameter	42
Gambar 4. 21 Hasil prediksi dan estimasi	43
Gambar 4. 22 Grafik visualisasi harga satuan	46
Gambar 4. 23 Diagram proporsi estimasi per jenis pekerjaan	47

DAFTAR TABEL

Tabel 3. 1 Reshape data	16
Tabel 3. 2 Long format setelah diurutkan.....	17
Tabel 3. 3 one hot encoding jenis_pekerjaan.....	17
Tabel 3. 4 Data kolom tahun setelah di normalisasi	18
Tabel 3. 5 Data kolom harga satuan nama pekerjaan setelah di normalisasi	19
Tabel 3. 6 Flowchart alur sistem	26
Tabel 4. 1 Data aktual dan data prediksi	33
Tabel 4. 2 kolom error.....	34
Tabel 4. 3 kolom error.....	35
Tabel 4. 4 kolom APE.....	35
Tabel 4. 5 Kolom Aktual.....	36



ABSTRAK

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—from 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

ABSTRACT

This research aims to develop a web-based system for predicting unit prices and estimating road construction project costs using an Artificial Neural Network (ANN) model with a Multilayer Perceptron (MLP) architecture and the backpropagation algorithm. The model generates predictions in the form of unit prices and total cost estimations. It was trained using historical data of unit prices from four types of roadwork—Aggregate Base Course (LPA), Hard Seal Coat, Burda Aggregate Cover, and Manual Latasir—from 2017 to 2024. The dataset underwent preprocessing steps including cleaning, transformation to long format, encoding, and normalization. The training process was conducted over 300 epochs with a batch size of 32 and 20% validation data. Evaluation results showed strong model performance, with a Mean Squared Error (MSE) of 598,031,344.79, Mean Absolute Error (MAE) of 12,923.91, Mean Absolute Percentage Error (MAPE) of 24.68%, and a coefficient of determination (R^2) of 0.9818. The model's output visualizations, including scatter plots and distribution histograms, demonstrated consistent proximity between actual and predicted values. These results confirm that the ANN model is capable of producing accurate unit price predictions. The system was implemented as a web application using Streamlit, enabling users to input parameters (year, road dimensions, and VAT rate) and automatically obtain unit price predictions and total cost estimations, making it a useful tool for supporting decision-making in project budgeting and planning.

Keywords : ANN, Prediction, Evaluation, Estimation, Streamlit.

BAB I

PENDAHULUAN

1.1 LATAR BELAKANG

Industri konstruksi memiliki peran penting dalam mendorong pertumbuhan ekonomi suatu negara. Dalam penelitian (Utomo dkk., 2023) Indonesia memberikan lebih dari 67% kontribusi terhadap pasar konstruksi ASEAN dan keuntungan yang bisa didapat jasa konstruksi menjadi yang tertinggi di ASEAN. Selain memberi keuntungan untuk kontraktor, pembangunan juga membuka lapangan pekerjaan 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 (AlTalhoni dkk., 2024) 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 (Nasution, 2024). 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 (Soeharto, 1997). 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 (ZAHIR & MUHLIS, 2022) 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 (Mahamid, 2013), 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 (Bimantoro dkk., 2021). Dalam sistem estimasi biaya proyek peningkatan jalan, backpropagation berkontribusi pada peningkatan akurasi estimasi biaya dengan memanfaatkan data proyek sebelumnya.

Penelitian ini bertujuan untuk mengimplementasikan sistem prediksi harga satuan serta estimasi biaya konstruksi jalan menggunakan jaringan syaraf tiruan menggunakan pelatihan algoritma backpropagation dengan 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.

1.2 PERUMUSAN MASALAH

- 1) Bagaimana memprediksi harga satuan pekerjaan berdasarkan tahun ?
- 2) Bagaimana sistem dapat menghitung total estimasi biaya berdasarkan dimensi proyek ?

1.3 PEMBATASAN MASALAH

Batasan masalah yang akan dibuat adalah sebagai berikut :

- 1) Jenis pekerjaan terbatas pada Lapis Pondasi Agregat, Agregat Burda, Pelaburan Keras, dan Latasir Manual,
- 2) Data yang digunakan dalam pengembangan sistem berasal dari HSP (Harga Satuan Pekerjaan) dari tahun 2017 hingga 2024,
- 3) Model memprediksi berdasarkan input tahun dan variabel panjang, lebar, ketebalan jalan

1.4 TUJUAN

- 1) Mengimplementasikan sistem prediksi harga satuan pekerjaan jalan menggunakan ANN berbasis web untuk menghitung estimasi biaya dari input panjang, lebar, ketebalan, dan PPN sehingga nilai hasil prediksi nya bisa dijadikan acuan dalam pembuatan RAB (Rencana Anggaran Biaya).

1.5 MANFAAT

Penelitian ini membantu calon pemilik proyek dan kontraktor menganalisa harga satuan di tahun yang akan datang dan mengestimasi harga nya berdasarkan variabel panjang, lebar, ketebalan, serta ppn

1.6 SISTEMATIKA PENULISAN

BAB I : PENDAHULUAN

Bab ini berisi uraian mengenai latar belakang penelitian, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian.

BAB II : TINJAUAN PUSTAKA DAN LANDASAN TEORI

Bab ini menguraikan penelitian terdahulu yang relevan dalam lima tahun terakhir serta landasan teori yang mendukung penerapan jaringan syaraf tiruan untuk sistem estimasi biaya proyek peningkatan jalan.

BAB III : METODOLOGI PENELITIAN


Bab ini menjelaskan langkah-langkah penelitian yang meliputi pengumpulan data, pengolahan data, pelatihan model, evaluasi model.

BAB IV : HASIL PENELITIAN DAN PEMBAHASAN

Bab ini menyajikan hasil penelitian, hasil prediksi harga satuan pekerjaan dari pelatihan, hasil estimasi biaya proyek serta menampilkan tampilan website sistem estimasi biaya proyek peningkatan jalan

BAB V : KESIMPULAN DAN SARAN

Bab ini memuat kesimpulan proses penelitian dari awal hingga akhir (selesai) serta memamparkan pengembangan sistem dalam bentuk saran yang bisa dijadikan referensi untuk penelitian selanjutnya.



BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Pada penelitian yang dilakukan oleh Yoszy Aldo Tondayana dan Doddy Prayogo yang mengeksplorasi penerapan metode Artificial Neural Network (ANN) untuk memprediksi biaya konstruksi bangunan dengan mempertimbangkan faktor makroekonomi menunjukkan bahwa model ANN memiliki kinerja yang lebih baik 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 (Tondayana & Prayogo, 2024). Penelitian ini menegaskan bahwa penggunaan metode ANN lebih efektif dalam memperkirakan biaya konstruksi.

Dalam sebuah penelitian tahun 2021 dengan judul “Estimasi Pemberantasan Hama di Kebun Bah Jambi Menggunakan Algoritma Backpropagation” yang dilakukan oleh Agung Bimantoro dkk. Penggunaan arsitektur backpropagation dalam penelitian ini menggarisbawahi potensi metode ini dalam meningkatkan efisiensi dan efektivitas pengelolaan sumber daya di bidang pertanian (Bimantoro dkk., 2021).

Pada 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. Ini menunjukkan bahwa model ANN mampu memberikan estimasi biaya yang cukup akurat (Dewanti dkk., 2021).

Pada penelitian yang dilakukan oleh Yesia Tahapari dkk yang berjudul “Model Estimasi Biaya Dengan Cost Significant Model Dan Artificial Neural Network Proyek Peningkatan Jalan Aspal Di Yogyakarta”, mereka membandingkan akurasi pada metode untuk estimasi biaya proyek peningkatan jalan, yaitu Cost Significant Model (CSM) dan Artificial Neural Network (ANN). Dengan menggunakan 28 data

proyek dari tahun 2010 hingga 2019 ini menyimpulkan bahwa metode ANN lebih unggul dibandingkan dengan CSM dalam estimasi biaya proyek peningkatan jalan aspal. Model ANN-2 yang menggunakan sepuluh variabel CSI memberikan hasil estimasi biaya dengan akurasi yang lebih tinggi (MAPE 8,132%) dibandingkan dengan CSM (MAPE 14,76%). Oleh karena itu, penggunaan ANN direkomendasikan sebagai alternatif yang lebih efisien untuk estimasi biaya proyek konstruksi (Tahapari dkk., 2021).

Penelitian dengan judul “Pemodelan Artificial Neural Network untuk Estimasi Biaya Proyek Peningkatan Jalan Aspal dengan Variabel Bebas Dimensi Item Pekerjaan” menunjukkan bahwa pemodelan *Artificial Neural Network* (ANN) dapat digunakan untuk estimasi biaya proyek peningkatan jalan aspal dengan akurasi yang tinggi. Model dengan 20 neuron pada hidden layer memberikan hasil terbaik dengan MAPE sebesar 2.77% (Akbar dkk., 2024). Hasil ini menegaskan potensi ANN sebagai alat bantu yang efektif dalam estimasi biaya pada tahap konseptual proyek, yang dapat mengurangi ketidakpastian dan meningkatkan keakuratan estimasi.

Penelitian yang berjudul “Estimasi Harga Bawang Merah di Jawa Timur Menggunakan Model Multilayer Perceptron (MLP)” oleh (Pradana dkk., 2023), membuktikan bahwa model Artificial Neural Network khususnya arsitektur MLP mampu memberikan hasil prediksi harga yang baik dengan tingkat kesalahan (MAPE) terendah sebesar 1,77% pada skenario pelatihan terbaik (rasio data latih dan uji 2:1, epoch 100). Performa prediksi terbukti sangat tergantung pada konfigurasi jumlah epoch dan rasio data, di mana kombinasi yang tepat menghasilkan tingkat akurasi tinggi.

Penelitian ini sangat relevan dengan penelitian saya yang juga menerapkan model ANN untuk melakukan estimasi harga satuan pekerjaan proyek peningkatan jalan. Sama seperti prediksi harga bawang yang bersifat fluktuatif dan dipengaruhi banyak faktor, harga satuan pekerjaan konstruksi juga mengalami dinamika tahunan yang kompleks. Model ANN, khususnya Multilayer Perceptron dengan algoritma backpropagation, terbukti efektif dalam menangkap pola non-linear dalam data dan mampu menghasilkan prediksi yang presisi, menjadikannya metode yang tepat untuk digunakan dalam sistem estimasi biaya proyek konstruksi seperti yang saya rancang.


Berdasarkan beberapa penelitian di atas, penggunaan Artificial Neural Network (ANN), khususnya arsitektur Multilayer Perceptron (MLP) dengan algoritma backpropagation, sangat tepat untuk diterapkan dalam sistem estimasi biaya.

Keberhasilan model ini dalam menangkap hubungan non-linear antar variabel serta menghasilkan estimasi yang akurat menunjukkan potensinya dalam meningkatkan efisiensi dan akurasi estimasi biaya proyek konstruksi, termasuk proyek peningkatan jalan. Dengan performa ANN yang terbukti dalam berbagai studi, terdapat peluang besar untuk mengembangkan penelitian lebih lanjut dalam penerapan metode ini pada sistem estimasi berbasis data historis konstruksi.

2.2 Dasar Teori

2.2.1 Metode Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) atau Artificial Neural Network (ANN) adalah suatu model komputasi yang terinspirasi dari struktur dan cara kerja otak manusia dalam memproses informasi. JST terdiri dari sejumlah besar elemen pemroses sederhana yang disebut neuron atau node, yang saling terhubung satu sama lain dan bekerja secara paralel untuk memecahkan suatu masalah tertentu. Menurut (Sujjada dkk., 2023), Jaringan syaraf tiruan cocok digunakan dalam berbagai bidang, seperti pengenalan pola, pengenalan suara, pemrosesan bahasa alami dan prediksi.



Gambar 6. 1 Model arsitektur ann

Setiap neuron di dalam jaringan terhubung dengan neuron lainnya melalui bobot (weights) yang disesuaikan selama proses pelatihan. Nilai bobot ini menentukan seberapa besar pengaruh sebuah neuron terhadap neuron lainnya.

Proses pelatihan JST biasanya melibatkan dua tahap utama :

1. *Forward Propagation*

Forward propagation merupakan tahap pertama dalam proses kerja Jaringan Syaraf Tiruan (*Artificial Neural Network* / ANN). Pada tahap ini, data *input* mengalir dari lapisan *input*, melalui lapisan tersembunyi (*hidden layer*), hingga mencapai lapisan *output*, untuk menghasilkan prediksi atau hasil keluaran dari jaringan.

2. *Backward Propagation*

algoritma inti dalam proses pelatihan Jaringan Syaraf Tiruan (*Artificial Neural Network* / ANN). Setelah proses *forward propagation* menghasilkan prediksi, *backpropagation* digunakan untuk menghitung *error* (kesalahan) dan mengubah bobot jaringan agar kesalahan tersebut menjadi semakin kecil.

Alur proses ANN adalah sebagai berikut :

1. Pengumpulan Data

- Mengumpulkan data input (fitur) dan output (target) dari studi kasus, contoh : tahun, panjang, lebar, ketebalan, harga satuan pekerjaan.

2. Pra – Pemrosesan Data

- Cleaning data dari nilai kosong atau anomali
- Melakukan normalisasi atau standarisasi nilai agar berada dalam skala yang sesuai untuk pelatihan. Contoh: Normalisasi nilai harga dari skala asli ke nilai 0–1.

3. Penentuan Arsitektur ANN

- Memilih jumlah neuron dan lapisan (input, hidden, output).
Contoh: Input = jumlah variabel (tahun, panjang, lebar, dll.),
Hidden = 1–2 lapisan, Output = 1 neuron (harga satuan).

4. Inisialisasi Bobot dan Bias

- Berikan nilai awal acak pada bobot dan bias antar neuron.

5. Forward Propagation

- Data input diteruskan dari lapisan input ke hidden layer hingga lapisan output.
- Menggunakan fungsi aktivasi (misalnya ReLU) untuk mendapatkan nilai output dari setiap neuron.

6. Hitung Nilai Error (Loss)

- Membandingkan nilai output dengan nilai target (aktual) dengan fungsi loss (misalnya MSE) untuk menghitung tingkat kesalahan.

7. Backward Propagation

- Menghitung nilai gradien dari error untuk masing-masing bobot dan bias.
- Menyesuaikan bobot dan bias sesuai nilai gradien dengan metode optimasi (misalnya Gradient Descent atau Adam).

8. Iterasi atau Epoch

- Mengulangi proses forward dan backward propagation hingga jumlah epoch yang ditentukan atau hingga nilai error berada di bawah nilai tertentu.

9. Evaluasi Model

- Mengukur performa model dengan metrik evaluasi (MSE, RMSE, MAPE, R^2) untuk mengetahui tingkat akurasi.

10. Penggunaan Model untuk Prediksi

- Model yang sudah dilatih digunakan untuk memprediksi nilai output dari data input baru (misalnya estimasi biaya untuk tahun tertentu).

2.2.2 Backpropagation

Backpropagation adalah algoritma pembelajaran terarah (supervised learning) yang digunakan untuk melatih jaringan syaraf tiruan multilayer (multilayer perceptron). Tujuan utama dari algoritma ini adalah meminimalkan error atau selisih antara output jaringan dengan target sebenarnya, dengan cara memperbarui bobot koneksi dalam jaringan. Metode backpropagation bekerja dengan cara menghitung gradien dari kesalahan yang dihasilkan oleh jaringan terhadap setiap bobot, dan kemudian mengubah bobot-bobot tersebut berdasarkan gradien tersebut (Pragana dkk., 2023).

Backpropagation berperan penting dalam proses pelatihan Jaringan Syaraf Tiruan (JST) karena memungkinkan jaringan untuk belajar dari kesalahan prediksi yang dihasilkan. Proses ini dimulai dengan mengukur tingkat kesalahan atau loss yang terjadi antara output prediksi jaringan dan nilai target yang sebenarnya. Kesalahan ini kemudian digunakan sebagai dasar untuk memperbarui parameter jaringan,

yaitu bobot dan bias, melalui algoritma optimasi seperti gradient descent (Rifky dkk., 2025). Tujuan utama dari proses pembaruan ini adalah untuk meminimalkan nilai error secara bertahap. Dengan demikian, JST mampu menyesuaikan diri terhadap pola-pola dalam data melalui proses pembelajaran yang bersifat iteratif, sehingga meningkatkan akurasi prediksi dalam setiap epoch pelatihan.

Di dalam jaringan, proses pembelajaran sangat dipengaruhi oleh jenis fungsi aktivasi yang digunakan. Fungsi aktivasi seperti ReLU (Rectified Linear Unit) berperan penting dalam mentransformasikan output dari neuron agar dapat diteruskan ke lapisan berikutnya secara efisien. ReLU dinilai paling tepat digunakan dalam model ini karena mampu menghindari masalah vanishing gradient yang sering terjadi pada fungsi aktivasi seperti sigmoid, serta lebih cepat dalam mencapai konvergensi pada jaringan dengan banyak lapisan tersembunyi (Bintang & Imaduddin, 2024). Hal ini sangat relevan dalam sistem estimasi biaya proyek yang memerlukan akurasi tinggi terhadap data input numerik berskala besar.

Langkah awal yang sangat penting dalam pelatihan jaringan syaraf tiruan (JST) adalah mengukur seberapa jauh prediksi model berbeda dari nilai yang seharusnya. Untuk itu, digunakan suatu rumus matematis yang disebut sebagai fungsi error atau fungsi kerugian (loss function). Salah satu fungsi kerugian yang paling umum digunakan adalah Mean Squared Error (MSE). Rumus MSE adalah sebagai berikut :

$$E = \frac{1}{n} \sum_{i=1}^n (\psi_i - \hat{\psi}_i)^2$$

Keterangan :

E = nilai error total (MSE)

n = jumlah data (misalnya, 100 data pelatihan)

ψ_i = nilai target sebenarnya (misalnya, biaya sebenarnya dari suatu proyek)

$\hat{\psi}_i$ = output prediksi dari JST untuk data ke- i

MSE menghitung rata-rata dari kuadrat selisih antara nilai prediksi ($\hat{\psi}_i$) dan nilai sebenarnya (ψ_i). Dengan mengkuadratkan selisih, fungsi ini memastikan bahwa semua nilai error menjadi positif dan memberikan penalti yang lebih besar untuk kesalahan yang besar (Farhana, 2025).

Dalam proses pelatihan jaringan syaraf tiruan, proses backpropagation dilakukan untuk memperbarui bobot dan bias berdasarkan hasil perhitungan error. Salah satu pendekatan yang digunakan adalah algoritma gradient descent, yaitu metode untuk mencari nilai minimum dari fungsi kesalahan (loss function) dengan cara melangkah ke arah negatif gradien. Proses pembaruan bobot dalam algoritma gradient descent dirumuskan sebagai berikut :

$$w_{baru} = w_{lama} - \alpha \cdot \frac{\partial E}{\partial w}$$

di mana w_{lama} adalah bobot saat ini, α merupakan learning rate yang mengatur besar langkah pembaruan, dan $\frac{\partial E}{\partial w}$ adalah turunan dari fungsi error terhadap bobot. Nilai gradien ini menunjukkan arah dan besar perubahan bobot yang perlu dilakukan untuk mengurangi error. Jika nilai gradien besar, maka pembaruan bobot akan lebih signifikan, dan sebaliknya.

Proses ini dapat dianalogikan seperti seseorang yang sedang belajar melempar bola ke tengah papan target. Pada percobaan pertama, lemparannya meleset jauh. Dari situ, orang tersebut mengevaluasi kesalahan arah dan kekuatan lemparannya, lalu memperbaiki cara melempar pada percobaan berikutnya. Jika koreksi arah terlalu besar, lemparan bisa meleset ke sisi lain. Jika koreksinya terlalu kecil, maka butuh waktu lama untuk mencapai sasaran. Demikian pula, learning rate dalam backpropagation mengatur seberapa besar koreksi bobot dilakukan agar model belajar secara efisien.

Dengan terus-menerus memperbarui bobot berdasarkan error yang dihitung, jaringan syaraf mampu menyesuaikan diri terhadap pola dalam data, sehingga menghasilkan prediksi yang semakin akurat (FAKHRYZA, 2024). Proses ini berlangsung secara iteratif dalam setiap epoch pelatihan, hingga nilai error menyentuh ambang minimum tertentu. Dalam konteks sistem estimasi biaya proyek jalan, pendekatan ini memungkinkan model JST untuk memperbaiki hasil prediksi biaya berdasarkan input seperti panjang, lebar, ketebalan, dan harga satuan pekerjaan.

2.2.3 Multi Layer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan salah satu arsitektur jaringan syaraf tiruan (Artificial Neural Network/ANN) yang paling banyak digunakan dalam

berbagai aplikasi prediksi dan klasifikasi. MLP terdiri dari tiga jenis lapisan utama: input layer yang menerima data masukan, satu atau lebih hidden layer yang melakukan pemrosesan melalui bobot dan fungsi aktivasi, serta output layer yang menghasilkan prediksi akhir. Struktur ini membuat MLP mampu menangani hubungan yang kompleks antar variabel (Nugroho, 2023).

Setiap neuron dalam MLP saling terhubung secara penuh (fully connected), dan proses pelatihannya biasanya menggunakan algoritma backpropagation. Algoritma ini menghitung error antara output dan target, lalu memperbarui bobot dengan pendekatan gradien menggunakan fungsi loss seperti MSE (Mukhtar dkk., 2021).

Keunggulan utama MLP adalah kemampuannya dalam memodelkan hubungan non-linear, sehingga sangat cocok digunakan untuk memecahkan permasalahan estimasi dengan banyak variabel dinamis, seperti harga atau volume konstruksi. Misalnya, (Pahlepi & Huda, 2024) menggunakan MLP untuk mendeteksi kelayakan minyak goreng dengan akurasi mencapai 85%.

2.2.4 Python

Python adalah bahasa pemrograman tingkat tinggi yang dirancang dengan filosofi yang menekankan keterbacaan kode dan sintaks yang bersih (Fatomi, 2021). Diciptakan oleh Guido van Rossum dan dirilis pertama kali pada tahun 1991, Python telah berkembang menjadi salah satu bahasa pemrograman yang paling populer di dunia. Python dikenal dengan sintaksnya yang mudah dipahami dan mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, fungsional, dan prosedural. Python mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek (OOP), prosedural, dan fungsional. Sebuah studi oleh (Dyer & Chauhan, 2022), menunjukkan bahwa dalam lebih dari 100.000 proyek Python open-source, paradigma OOP dan prosedural mendominasi, sementara fitur-fitur fungsional juga digunakan secara signifikan.

Python menyediakan berbagai tipe data dasar seperti integer, float, string, boolean, serta struktur data seperti list, tuple, set, dan dictionary (Apriani dkk., 2025). Variabel di Python tidak memerlukan deklarasi tipe secara eksplisit karena Python menggunakan tipe data dinamis. Hal ini memudahkan dalam penulisan kode dan mempercepat proses pengembangan. Python memiliki ekosistem pustaka yang luas, seperti NumPy untuk komputasi numerik, Pandas untuk manipulasi data, dan Matplotlib untuk visualisasi data (Apriani dkk., 2025; Fatomi, 2021). Pustaka-

pustaka ini memungkinkan pengembangan aplikasi yang kompleks dengan efisiensi tinggi. Penggunaan pustaka ini telah terbukti efektif dalam berbagai penelitian, termasuk dalam analisis data akademik dan pemodelan matematika.

Python telah menjadi pilihan utama dalam pendidikan pemrograman karena sintaksnya yang sederhana dan mudah dipahami oleh (Zhang dkk., 2022). Selain itu, Python juga digunakan secara luas dalam penelitian ilmiah dan pengembangan teknologi karena kemampuannya dalam menangani berbagai jenis data dan integrasi dengan pustaka-pustaka ilmiah.

2.2.5 Website

Website merupakan kumpulan halaman web yang saling terhubung dan dapat diakses melalui internet, berfungsi sebagai media penyampaian informasi, komunikasi, dan interaksi antara pengguna dan penyedia layanan. Perkembangan teknologi telah menjadikan website sebagai platform utama dalam berbagai sektor, termasuk pendidikan, bisnis, dan pemerintahan (Ekpobimi dkk., 2024).

Pengembangan website adalah proses teknis dan kreatif yang melibatkan berbagai tahapan untuk menghasilkan produk digital yang fungsional dan sesuai dengan kebutuhan pengguna. Secara umum, proses ini dimulai dari tahap analisis kebutuhan, diikuti dengan perancangan struktur dan antarmuka (UI/UX), pengkodean dan implementasi, hingga tahap pengujian, peluncuran, serta pemeliharaan jangka panjang (Al-Hawari dkk., 2021). Dalam implementasinya, proses pengembangan website juga mempertimbangkan aspek keamanan, responsivitas, skalabilitas, dan pengalaman pengguna yang optimal. Setiap tahapan tersebut sangat penting untuk memastikan bahwa sistem yang dibangun memiliki kinerja yang baik dan memenuhi standar kualitas yang diharapkan oleh pengguna dan pengembang.

Dalam beberapa tahun terakhir, pengembangan website telah mengalami perubahan signifikan yang dipengaruhi oleh pertumbuhan penggunaan perangkat mobile, tuntutan efisiensi proses pengembangan, serta peningkatan ekspektasi pengguna terhadap kecepatan dan kemudahan akses. Beberapa tren teknologi terkini yang banyak diterapkan dalam pengembangan website antara lain adalah pendekatan mobile-first design, yang memprioritaskan tampilan dan fungsi untuk perangkat mobile sebelum versi desktop; progressive web apps (PWA) yang menggabungkan keunggulan aplikasi web dan aplikasi mobile native; serta pengembangan menggunakan platform low-code dan no-code yang memungkinkan

pengguna non-teknis turut membangun aplikasi web secara cepat tanpa banyak menulis kode program(Hrishikesh & Patel, 2025). Penerapan tren ini tidak hanya mempercepat proses pengembangan, tetapi juga meningkatkan jangkauan layanan dan pengalaman pengguna.

Kinerja front-end website memainkan peran yang sangat krusial dalam menentukan seberapa baik pengguna dapat berinteraksi dengan aplikasi web. Faktor-faktor seperti waktu pemuatan halaman, kecepatan respon interaksi, dan efisiensi dalam penggunaan data menjadi indikator penting dalam menilai kualitas sebuah website. Menurut (Ekpobimi dkk., 2024) berbagai strategi optimasi digunakan, seperti teknik pemisahan kode (code splitting) agar halaman tidak memuat seluruh komponen secara bersamaan, pemuatan lambat (lazy loading) untuk konten dinamis, caching untuk mempercepat pengambilan data berulang, serta minifikasi file CSS dan JavaScript untuk mengurangi ukuran file. Optimalisasi front-end yang tepat terbukti dapat meningkatkan kepuasan pengguna, mempercepat proses transaksi, dan menurunkan rasio pengabaian (bounce rate).




BAB III

METODE PENELITIAN

3.1 Metodologi penelitian

Penelitian ini menggunakan metode atau algoritma *Artificial Neural Network* (ANN), memiliki beberapa tahapan yang perlu dilakukan. Alur metodologi penelitian dapat dilihat pada gambar 3.1.



Gambar 7. 1 Flowchart metode penelitian

3.1.1 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 7.1 memperlihatkan dataset yang akan digunakan dalam penelitian ini.

Tabel 7. 1 Dataset harga satuan pekerjaan proyek jalan tahunan.

Tahun	LPA (m ³)	Pelaburan (Ltr)	Burda (m ²)	Latasir (m ²)
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

3.1.2 Data Cleaning

Cleaning data merupakan proses membersihkan, memperbaiki, dan menyusun data agar siap digunakan dalam analisis atau pemodelan. Dalam penelitian ini mencakup pembersihan data dengan menghapus kolom yang tidak diperlukan seperti kolom nomer.

3.1.3 Preprocessing Data

Tahap preprocessing pada penelitian ini memerlukan reshape data ke long format, normalisasi pada tahun dan harga satuan, dan encoding :

1) *Reshape* Data ke Long Format

Proses *reshape* data ini intinya mengubah struktur data *wide* (setiap jenis pekerjaan sebagai kolom) ke *long* format (setiap baris mewakili tahun dan jenis pekerjaan). Format *long* digunakan karena untuk memastikan data dari fitur/kategori dapat mudah proses, membentuk struktur tabular yang cocok untuk input model *multi-output*, serta mempermudah visualisasi dan pemanggilan batch dalam pelatihan model. Contoh tabel *long* format sebagai berikut :

Tabel 3. 1 *Reshape* data

Tahun	Jenis_pekerjaan	Harga_satuan
2017	LPA	Rp 345,879.47
2018	LPA	Rp 339,256.78
2019	LPA	Rp 348,744.24

Sebelum ke processing data alangkah lebih baik jika di urutkan terlebih dahulu sesuai tahun dan jenis pekerjaan. Proses ini mencegah hasil prediksi tidak sesuai dengan tahun dan jenis pekerjaan.

Contoh tabel jika sudah di urutkan adalah sebagai berikut :

Tabel 3. 2 Long format setelah diurutkan

Tahun	Jenis_pekerjaan	Harga_satuan
2017	LPA	Rp 345,879.47
2017	Pelaburan Keras	Rp 9,532.62
2017	Burda	Rp 30,093.02
2017	Latasir manual	Rp 61,720.08
2018	LPA	Rp 339,256.78

2) One Hot-Encoding

Encoding adalah proses mengubah data non-numerik menjadi format numerik agar bisa diproses oleh machine learning. Contoh tabel yang sudah di ubah ke one hot encoding adalah sebagai berikut

Tabel 3. 3 one hot encoding jenis pekerjaan

Tahun	Harga_satuan	LPA	Pelaburan	Burda	Latasir
2017	Rp 345,879.47	1	0	0	0
2017	Rp 9,532.62	0	1	0	0
2017	Rp 30,093.02	0	0	1	0
2017	Rp 61,720.08	0	0	0	1
2018	Rp 339,256.78	1	0	0	0

3) Normalisasi tahun dan harga satuan ke skala 0 – 1

Normalisasi adalah proses transformasi fitur numerik ke dalam skala tertentu, biasanya antara 0 sampai 1, untuk memastikan bahwa semua fitur memiliki kontribusi yang seimbang dalam model. Normalisasi menggunakan rumus :

$$x^t = \frac{x - x_{min}}{x_{max} - x_{min}}$$

x = Nilai yang ingin di normalisasi

x^t = Hasil nilai yang di sudah normalisasi

x_{max} = Nilai maksimal dalam kolom

x_{min} = Nilai minimal dalam kolom

a) Normalisasi Tahun

Normalisasi tahun pada penelitian ini yaitu dengan mengubah nilai tahun (2017–2024) menjadi rentang 0–1 agar skala input ke model

seragam dan mempermudah proses pembelajaran. Jika tidak dinormalisasi maka Tahun 2024 bisa dianggap "lebih besar" secara signifikan dibanding nilai input lain (misalnya biner 0/1) Ini bisa menyebabkan gradien jadi tidak stabil saat backpropagation. Dengan normalisasi setiap fitur memiliki skala yang seragam, Proses optimasi (gradient descent) lebih cepat dan akurat. Tabel 7.4 adalah dataset yang kolom tahun nya sudah di normalisasi.

Tabel 3. 4 Data kolom tahun setelah di normalisasi

Tahun	Harga_satuan	LPA	Pelaburan	Burda	Latasir
0.00	Rp 345,879.47	1	0	0	0
0.00	Rp 9,532.62	0	1	0	0
0.00	Rp 30,093.02	0	0	1	0
0.00	Rp 61,720.08	0	0	0	1
0.14	Rp 339,256.78	1	0	0	0

Perhitungan menggunakan rumus normalisasi atau min-max scaling dengan contoh perhitungannya sebagai berikut :

- Normalisasi tahun 2017 :

$$X^i \frac{2017 - 2017}{2024 - 2017} = \frac{0}{7} = 0$$

- Normalisasi tahun 2024 :

$$X^i \frac{2024 - 2017}{2024 - 2017} = \frac{7}{7} = 1$$

b) Normalisasi Harga Satuan di kolom nama pekerjaan

Kemudian normalisasi harga satuan pada penelitian ini yaitu mengubah nilai harga satuan menjadi rentang 0 sampai 1 karena model ANN menggunakan backpropagation yang bergantung pada nilai error/loss. Alasan lain di normalisasi karena nilai harga satuan termasuk dalam skala besar maka nilai error juga besar, gradien dalam proses pelatihan bisa terlalu tinggi yang membuat pelatihan tidak stabil atau lambat. Dengan normalisasi ini membantu ann berlatih lebih efisien dan cepat konvergen. Tabel 7.5 adalah dataset yang kolom harga satuannya jenis pekerjaan yang sudah di normalisasi.

Tabel 3. 5 Data kolom harga satuan nama pekerjaan setelah di normalisasi

Tahun	Harga_satuan	LPA	Pelaburan	Burda	Latasir
0.00	0.70	1	0	0	0
0.00	0.00	0	1	0	0
0.00	0.04	0	0	1	0
0.00	0.11	0	0	0	1
0.14	0.69	1	0	0	0

Perhitungan menggunakan rumus normalisasi atau min-max scaling dengan contoh perhitungannya sebagai berikut :

- Normalisasi harga satuan

$$X^i = \frac{345,879.47 - 9,532.62}{490,267.11 - 9,532.62} = \frac{336,346.85}{480,734.49} = 0.70$$

- Normalisasi harga satuan

$$X^i = \frac{9,532.62 - 9,532.62}{490,267.11 - 9,532.62} = \frac{0}{480,734.49} = 0.00$$

3.1.4 Fitur Dan Target

Tahap awal dalam proses pelatihan model jaringan syaraf tiruan (JST) adalah memisahkan data ke dalam dua komponen utama, yaitu data input (X) dan data target (y). Pemisahan ini diperlukan untuk mengidentifikasi secara eksplisit variabel independen (fitur) yang akan digunakan oleh model dalam melakukan prediksi, serta variabel dependen (target) yang merupakan hasil yang diharapkan dari proses pembelajaran. Pada penelitian ini, data input (X) terdiri dari fitur numerik berupa kolom Tahun yang telah dinormalisasi menggunakan metode Min-Max Scaling. Fitur ini dipilih karena tren harga satuan pekerjaan pada umumnya menunjukkan pola yang bergantung pada perkembangan waktu atau tahun pelaksanaan proyek. Sementara itu, data target (y) terdiri dari empat kolom harga satuan pekerjaan, yaitu :

1. Harga satuan Lapis Pondasi Agregat (LPA)
2. Harga satuan Pelaburan Keras
3. Harga satuan Agregat Penutup Burda
4. Harga satuan Latasir Manual

Keempat target tersebut merupakan variabel numerik kontinu yang telah melalui proses normalisasi dan akan dijadikan output dari model ANN. Dengan demikian,

arsitektur model yang dikembangkan bersifat multi-output regression, di mana satu input tahun akan dipetakan ke empat output prediksi harga satuan secara bersamaan.

Langkah ini penting agar model hanya menerima variabel input pada saat pelatihan dan dapat mengevaluasi kemampuan prediksinya terhadap variabel target, khususnya setelah melalui proses pembagian data menjadi data pelatihan dan data pengujian.

3.1.5 Pelatihan Model

Dataset yang digunakan dalam tahap pelatihan terdiri atas dua subset, yaitu data pelatihan dan data validasi. Data pelatihan digunakan untuk melatih model agar dapat mengenali pola hubungan antara input tahun dan harga satuan empat jenis pekerjaan jalan, sedangkan data validasi digunakan untuk mengevaluasi performa model pada data yang tidak dilatih secara langsung. Dalam proses pelatihan, model diberi input dari data pelatihan dan menghasilkan output prediksi. Prediksi ini kemudian dibandingkan dengan data aktual untuk menghitung error, yang digunakan oleh algoritma backpropagation guna memperbarui bobot dan bias model.

Proses pelatihan ini dilakukan secara iteratif selama sejumlah epoch (dalam penelitian ini sebanyak 300 epoch), dengan setiap epoch merepresentasikan satu putaran penuh penggunaan seluruh data pelatihan. Untuk meningkatkan efisiensi, data pelatihan dibagi ke dalam mini-batch berukuran 32, sehingga dalam satu epoch, model melakukan beberapa pembaruan bobot berdasarkan batch secara bertahap. Setelah setiap epoch, model juga diuji terhadap data validasi untuk memantau nilai loss dan mendeteksi potensi overfitting.

Jika performa model pada data validasi menunjukkan kecenderungan memburuk, sedangkan akurasi pada data pelatihan terus meningkat, maka dapat disimpulkan bahwa model mulai mengalami overfitting. Oleh karena itu, evaluasi terhadap loss validasi digunakan sebagai indikator utama dalam menentukan apakah pelatihan perlu dilanjutkan, dihentikan, atau disesuaikan parameternya. Proses ini dilakukan secara berulang hingga model mencapai tingkat kesalahan minimum yang stabil dan performa validasi yang optimal, yang menandakan bahwa model telah belajar secara efektif dan mampu melakukan prediksi dengan akurasi tinggi terhadap data baru.

3.1.6 Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan beberapa metrik evaluasi regresi untuk menilai akurasi prediksi harga satuan dari keempat jenis pekerjaan. Salah satu metrik utama yang digunakan adalah Mean Squared Error (MSE), yang memberikan informasi mengenai besarnya kesalahan rata-rata kuadrat antara nilai prediksi dan nilai aktual. Semakin kecil nilai MSE, semakin baik performa model dalam memetakan hubungan antara input (tahun) dan output (harga satuan).

Selain itu, digunakan juga Mean Absolute Percentage Error (MAPE) untuk mengukur rata-rata kesalahan dalam bentuk persentase relatif terhadap nilai aktual. MAPE dinilai memberikan perspektif yang lebih mudah dipahami karena menyatakan seberapa jauh hasil prediksi menyimpang dari nilai sebenarnya dalam satuan persen. Dengan demikian, metrik ini berguna untuk menilai kepraktisan model dalam konteks penggunaan di dunia nyata.

Selanjutnya, digunakan Root Mean Squared Error (RMSE) yang merupakan akar dari MSE. RMSE memiliki satuan yang sama dengan data asli (dalam hal ini satuan harga), sehingga memberikan interpretasi yang lebih intuitif mengenai besarnya kesalahan prediksi yang terjadi. Nilai RMSE yang rendah menunjukkan bahwa prediksi model mendekati harga satuan aktual yang digunakan dalam pelaksanaan proyek jalan.

Evaluasi juga diperkuat dengan menggunakan koefisien determinasi (R^2) untuk menilai sejauh mana variabilitas harga satuan yang sebenarnya dapat dijelaskan oleh model. Nilai R^2 yang mendekati 1 menunjukkan bahwa model mampu menjelaskan proporsi besar dari variasi harga satuan, menandakan bahwa model memiliki akurasi dan daya generalisasi yang tinggi.

Berdasarkan nilai-nilai MSE, RMSE, MAPE, dan R^2 yang diperoleh, dapat disimpulkan bahwa model ANN yang telah dilatih memiliki performa yang baik dalam memprediksi harga satuan pekerjaan konstruksi jalan. Evaluasi ini penting untuk memastikan bahwa model yang dibangun tidak hanya mampu belajar dari data pelatihan, tetapi juga dapat digunakan secara andal dalam sistem estimasi biaya proyek di lapangan.

Dalam penelitian ini, model ANN digunakan untuk memprediksi harga satuan yang merupakan data numerik kontinu, sehingga tergolong sebagai permasalahan regresi. Oleh karena itu, evaluasi model dilakukan menggunakan metrik regresi seperti MSE, RMSE, MAPE, dan R^2 . Metrik-metrik ini mampu mengukur seberapa

dekat hasil prediksi dengan nilai aktual. Sebaliknya, metrik klasifikasi seperti confusion matrix, accuracy, precision, recall, dan F1-score tidak digunakan karena hanya cocok untuk output berupa kategori, bukan nilai kontinu.

3.1.7 Visualisasi Hasil

Untuk memberikan gambaran yang lebih jelas mengenai performa model dan kualitas hasil prediksi, dilakukan beberapa visualisasi pada tahap evaluasi. Visualisasi ini penting untuk memahami perilaku model selama proses pelatihan serta mengukur sejauh mana model mampu memprediksi harga satuan pekerjaan secara akurat.

Pertama, dilakukan plot nilai loss terhadap epoch selama proses pelatihan. Plot ini menggambarkan perubahan nilai loss pada data pelatihan dan data validasi seiring bertambahnya epoch. Dengan membandingkan kedua kurva ini, dapat diketahui apakah model mengalami overfitting atau underfitting. Overfitting terjadi ketika loss pelatihan menurun tajam tetapi loss validasi meningkat, sedangkan underfitting terjadi jika kedua nilai loss tetap tinggi. Pada hasil pelatihan model ini, terlihat bahwa kurva loss menunjukkan tren menurun pada kedua subset data, yang mengindikasikan bahwa model berhasil belajar secara bertahap dan memperbaiki kesalahan prediksinya.

Kedua, dibuat scatter plot antara nilai prediksi dan nilai aktual harga satuan untuk setiap jenis pekerjaan. Scatter plot ini bertujuan untuk menunjukkan sejauh mana hasil prediksi mendekati nilai sebenarnya. Dalam kondisi ideal, titik-titik prediksi akan tersebar mengikuti garis diagonal ($y = x$), yang menunjukkan bahwa model melakukan prediksi yang akurat. Penyimpangan titik-titik dari garis tersebut mengindikasikan adanya deviasi antara hasil prediksi dan nilai aktual, yang mencerminkan besarnya error.

Ketiga, dilakukan histogram distribusi harga satuan untuk membandingkan sebaran nilai harga satuan aktual dan nilai yang diprediksi oleh model. Histogram ini membantu mengevaluasi apakah model mampu menangkap pola distribusi harga yang ada dalam data historis. Perbedaan signifikan antara kedua histogram dapat menunjukkan bahwa model memiliki bias sistematis atau kesalahan dalam mempelajari distribusi nilai dari data pelatihan.

Keempat, ditampilkan visualisasi hasil prediksi untuk semua jenis pekerjaan berdasarkan input tahun pengguna. Visualisasi ini disajikan dalam bentuk bar chart atau tabel interaktif pada antarmuka sistem berbasis web. Tujuannya adalah

memberikan transparansi kepada pengguna mengenai harga satuan yang diprediksi oleh model, sebelum dikalikan dengan volume untuk menghasilkan estimasi biaya total.

Melalui serangkaian visualisasi ini, diperoleh gambaran menyeluruh mengenai akurasi dan konsistensi model dalam melakukan prediksi. Visualisasi juga berperan penting dalam mengidentifikasi potensi masalah seperti ketidaksesuaian tren, deviasi nilai prediksi yang besar, atau pola distribusi harga yang tidak ditangkap oleh model.

3.1.8 Implementasi Prediksi Harga Satuan

Setelah model ANN dilatih dan dievaluasi, tahap berikutnya adalah implementasi sistem prediksi harga satuan berdasarkan input tahun dari pengguna. Input ini dapat berupa tahun target (misalnya 2025 atau 2026) yang belum tersedia dalam data historis. Model kemudian menghasilkan prediksi harga satuan untuk empat jenis pekerjaan konstruksi jalan, yaitu :

- 1) Lapis Pondasi Agregat (LPA)
- 2) Pelaburan Keras
- 3) Agregat Penutup Burda
- 4) Latasir Manual

Prediksi yang dihasilkan berupa nilai numerik (dalam satuan Rp per m² atau Rp per m³), dan diubah kembali dari skala normalisasi ke nilai asli (denormalisasi). Implementasi ini memungkinkan sistem digunakan untuk memperkirakan harga satuan pada tahun-tahun mendatang tanpa perlu menghitung manual berdasarkan indeks atau referensi harga.

3.1.9 Perhitungan Estimasi Berdasarkan Volume Pekerjaan

Setelah harga satuan diperoleh melalui prediksi, langkah selanjutnya adalah menghitung estimasi biaya total berdasarkan input volume dari pengguna, yang mencakup panjang, lebar, dan ketebalan pekerjaan jalan. Volume dihitung secara otomatis oleh sistem berdasarkan rumus masing-masing jenis pekerjaan :

Tabel 7. 2 Rumus mencari volume

Jenis Pekerjaan	Rumus
Lapis Pondasi Agregat (LPA)	Panjang × lebar × ketebalan
Pelaburan Keras	Panjang × lebar × 2,5
Agregat Penutup Burda	Panjang × lebar

Latasir Manual	Panjang × lebar
----------------	-----------------

Setelah volume dihitung, sistem melakukan kalkulasi estimasi biaya sebagai berikut :

$$\text{Estimasi Biaya} = \text{Volume} \times \text{Harga Satuan Prediksi}$$

Hasil akhir yang ditampilkan kepada pengguna berupa estimasi total untuk masing-masing jenis pekerjaan, serta total keseluruhan proyek ditambah dengan ppn yang pengguna masukkan.

3.1.10 Pengembangan Website

Pada tahap ini, sistem dikembangkan menggunakan platform Streamlit karena bersifat ringan, interaktif, dan memungkinkan pembangunan aplikasi data science tanpa kebutuhan frontend yang kompleks. Model ANN yang telah dilatih disimpan dalam format .keras dan diintegrasikan langsung ke aplikasi web.

Antarmuka pengguna dirancang sederhana dan responsif. input berupa tahun prediksi serta dimensi proyek (panjang, lebar, ketebalan). Sistem akan menampilkan hasil prediksi harga satuan dari empat jenis pekerjaan dan menghitung estimasi biaya berdasarkan volume.

Komponen antarmuka menggunakan elemen seperti st.number_input, st.selectbox, dan st.button, serta menampilkan output dalam bentuk tabel dan grafik.

3.2 Software Yang Digunakan

Dalam pelatihan model dan pengembangan web, penelitian ini membutuhkan beberapa library dan software yang digunakan selama proses input hingga output sehingga dapat berjalan sesuai dengan yang diharapkan. berikut daftar software yang digunakan :

A. Python 3.10.0

Python merupakan bahasa pemrograman tingkat tinggi yang bersifat fleksibel dengan fokus pada keterbacaan dan kesederhanaan sehingga mudah dalam penggunaannya. Penggunaan python versi 3.10.0 sebagai bahasa pemrograman adalah karena memiliki *library* yang lengkap dan bersifat *open source*.

B. Framework Streamlit

Streamlit merupakan framework pada python yang digunakan untuk membangun aplikasi web dibidang data science dan machine learning bersifat

open source. Dalam penelitian ini, framework streamlit digunakan untuk men-deploy aplikasi yang telah dibuat menggunakan bahasa pemrograman python.

C. *Library* Pandas

Berfungsi untuk membaca, membersihkan, dan memanipulasi data tabular agar siap digunakan dalam proses pelatihan model. pandas digunakan untuk menampilkan data input atau output dalam bentuk tabel dan menangani file unggahan dari pengguna seperti CSV atau Excel.

D. *Library* Numpy

Numpy digunakan untuk mengelola array numerik dan melakukan operasi matematika dasar seperti reshape, konversi, dan vektorisasi data.

E. *Library* Matplotlib

Matplotlib berperan dalam membuat grafik seperti loss terhadap epoch, grafik distribusi error, dan visualisasi performa model. serta digunakan untuk menampilkan grafik atau visualisasi hasil model secara interaktif di halaman web berbasis Streamlit.

F. *Library* Seaborn

Seaborn digunakan untuk membuat visualisasi statistik seperti heatmap korelasi antar fitur dan distribusi nilai target. Seaborn membantu menyajikan grafik analisis tren harga atau perbandingan prediksi dan data aktual dengan tampilan yang lebih estetik.

G. *Library* Joblib

Joblib berfungsi untuk menyimpan model machine learning yang telah dilatih ke dalam file .pkl agar dapat digunakan kembali tanpa perlu pelatihan ulang. Dalam pengembangan web digunakan untuk memuat model yang telah disimpan agar dapat langsung digunakan untuk prediksi berdasarkan input pengguna di aplikasi web.


H. *Library* Tensorflow

Tensorflow digunakan untuk membangun, melatih, dan mengevaluasi arsitektur Artificial Neural Network (ANN) yang memprediksi harga satuan pekerjaan.

I. *Library* Sckit-Learn

Scikit-learn digunakan untuk melakukan normalisasi data (seperti MinMaxScaler), membagi data pelatihan dan validasi, serta menghitung metrik evaluasi seperti MSE, RMSE, MAPE, dan R^2 .

3.3 Perancangan Sistem



Tabel 3. 6 Flowchart alur sistem

Pada gambar 3.6, disajikan sebuah flowchart yang menggambarkan urutan proses yang menghasilkan *output* prediksi harga satuan dan estimasi biaya pekerjaan. Jika di rincikan prosesnya maka seperti berikut :

- 1) Pengguna membuka aplikasi web,
Aplikasi dijalankan melalui browser dan dibangun menggunakan framework Streamlit.
- 2) Pengguna mengisi tahun prediksi,
Pengguna memasukkan tahun target (misalnya 2025 atau 2026) yang ingin diprediksi harga satuannya.
- 3) Pengguna mengisi dimensi proyek,
Pengguna menginput nilai :
 - Panjang pekerjaan jalan (dalam meter)
 - Lebar pekerjaan jalan (dalam meter)
 - Ketebalan lapisan (dalam meter, hanya untuk LPA)
- 4) Pengguna memasukkan PPN,
Contoh : 11%
- 5) Sistem menjalankan model ANN,
Model Artificial Neural Network (ANN) yang telah dilatih akan memproses

input tahun dan menghasilkan prediksi harga satuan untuk empat jenis pekerjaan :

- Lapis Pondasi Agregat (LPA)
- Pelaburan Keras
- Agregat Penutup Burda
- Latasir Manual

6) Sistem menghitung volume pekerjaan,

Berdasarkan data panjang, lebar, dan ketebalan (jika diperlukan), sistem menghitung volume pekerjaan untuk setiap jenis pekerjaan menggunakan rumus :

- LPA : $\text{Panjang} \times \text{Lebar} \times \text{Ketebalan}$
- Pelaburan Keras : $\text{Panjang} \times \text{Lebar} \times 2,5$
- Burda dan Latasir : $\text{Panjang} \times \text{Lebar}$

7) Sistem menghitung estimasi biaya,

Sistem mengalikan hasil prediksi harga satuan dengan volume pekerjaan untuk menghasilkan estimasi biaya per jenis pekerjaan.

8) Sistem menampilkan hasil ke pengguna,

Tabel berisi :

- Nama pekerjaan
- Harga satuan hasil prediksi (Rp)
- Volume pekerjaan (m^2/m^3)
- Estimasi biaya total (Rp)

Selain itu, sistem juga menyajikan informasi tambahan berupa :

- Total harga seluruh jenis pekerjaan sebelum PPN,
- Nilai PPN yang dihitung berdasarkan persentase yang dimasukkan oleh pengguna,
- Total harga setelah PPN,
- Serta hasil akhir yang telah dibulatkan ke bawah ke kelipatan 100 untuk kemudahan pelaporan dan estimasi biaya proyek.

BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil dan Analisis

Berdasarkan metode penelitian dilakukan data cleaning, data precessing, pelatihan data, dan evaluasi model dengan rincian sebagai berikut :

4.1.1 Data Cleaning

1) Menghapus Data Kosong

```
#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 4. 1 menghapus data kosong

Pada gambar 4.1 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.

4.1.2 Data Preprocessing

1) 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 4. 2 Mengubah tabel ke long format

Pada gambar 4.2 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 4. 3 Menampilkan hasil long format

Gambar 4.3 menunjukkan hasil dari perubahan tabel wide ke long format.

2) 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 4. 4 Mengurutkan kolom tabel

Pada gambar 4.4 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 4. 5 Hasil mengurutkan kolom tabel

Gambar 4.5 menunjukkan hasil dari perintah untuk mengurutkan tabel sehingga bisa di proses ke tahap selanjutnya.

3) One-hot Encoding

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

Gambar 4. 6 Encoding kolom jenis pekerjaan

Pada gambar 4.6 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.

df_encoded.head()

	Tahun	Harga_Satuan	Jenis_Pekerjaan_LPA	Jenis_Pekerjaan_Pelaburan Keras	Jenis_Pekerjaan_Burda	Jenis_Pekerjaan_Latasir Manual
0	2017	345,879.47	True	False	False	False
1	2017	9,532.62	False	True	False	False
2	2017	30,093.02	False	False	True	False
3	2017	61,720.08	False	False	False	True
4	2018	339,256.78	True	False	False	False

Gambar 4. 7 Hasil encoding kolom jenis pekerjaan

Gambar 4.7 menunjukkan hasil perintah untuk encoding kolom jenis pekerjaan berupa tabel yang ditampilkan 5 teratas.

4) 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 4. 8 Normalisasi kolom tahun dan harga satuan

Pada gambar 4.8 terdapat skrip `scaler_tahun = MinMaxScaler()`, `scaler_harga = MinMaxScaler()` yang berfungsi untuk membuat dua objek normalisasi *Min-Max* dari *library* scikit-learn, satu untuk kolom Tahun, satu lagi untuk Harga_Satuan. Tujuannya adalah mengubah nilai numerik ke rentang 0 sampai 1, agar model *neural network* lebih stabil saat pelatihan. Kemudian Normalisasi kolom Tahun dilakukan dengan perintah `df_encoded['Tahun']=scaler_tahun.fit_transform(df_encoded[['Tahun']])` setelah itu menyimpan *scaler* yang telah digunakan dalam format .pkl (*pickle file*) sehingga bisa digunakan kembali saat prediksi di antarmuka web.

df_encoded.head()

	Tahun	Harga_Satuan	Jenis_Pekerjaan_LPA	Jenis_Pekerjaan_Pelaburan Keras	Jenis_Pekerjaan_Burda	Jenis_Pekerjaan_Latansir Manual
0	0.00	0.70	True	False	False	False
1	0.00	0.00	False	True	False	False
2	0.00	0.04	False	False	True	False
3	0.00	0.11	False	False	False	True
4	0.14	0.69	True	False	False	False

Gambar 4. 9 Hasil normalisasi kolom tahun dan harga satuan

Gambar 4.9 menunjukkan hasil normalisasi kolom tahun dan harga satuan yang siap digunakan sebagai input ke model *Artificial Neural Network* (ANN)

5) Membagi Data Pelatihan 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 4. 10 Membagi data pelatihan dan uji

Pada gambar 4.10 menunjukkan skrip yang berfungsi untuk memisahkan dataset menjadi data pelatihan dan pengujian sebelum melatih model prediksi harga satuan. `X_all` digunakan sebagai input (fitur) dan `y_all` sebagai target yang ingin diprediksi, sementara `tahun_all` disertakan untuk referensi visualisasi. Dengan menggunakan `train_test_split`, model dapat dilatih dan diuji secara seimbang, dan menghasilkan evaluasi performa.

4.1.3 Pelatihan Model

1) Membuat Model

```
#membuat model
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(Dense(32, activation='relu'))
model.add(Dense(1))

model.compile(optimizer='adam', loss='mse')
```

Gambar 4. 11 Membuat model ann

Pada gambar 4.11 merupakan skrip untuk membangun model ANN berlapis (sequential) yang digunakan untuk masalah prediksi numerik seperti regresi harga satuan. Model terdiri atas tiga lapisan utama, yaitu dua hidden layer dan satu output layer. Hidden layer pertama terdiri atas 64 neuron dengan fungsi aktivasi ReLU (Rectified Linear Unit), yang berguna untuk memperkenalkan sifat non-linear dalam model serta menghindari permasalahan vanishing gradient. Jumlah neuron disesuaikan untuk menangkap kompleksitas hubungan antara variabel input dan output. Selain itu, parameter `input_shape` ditetapkan berdasarkan jumlah fitur pada data pelatihan, yang diperoleh dari `X_train.shape[1]`, sehingga model secara otomatis menyesuaikan dengan jumlah kolom input yang digunakan. Hidden layer kedua menggunakan 32 neuron dengan aktivasi ReLU yang sama, berfungsi untuk memadatkan representasi data dari lapisan sebelumnya. Sementara itu, lapisan output hanya terdiri dari satu neuron tanpa fungsi aktivasi, karena tugas akhir model adalah melakukan prediksi regresi terhadap nilai harga satuan, yang bersifat numerik dan kontinu. Model disusun menggunakan fungsi loss Mean Squared Error (MSE), yang umum digunakan dalam kasus regresi, serta optimizer Adam untuk memperbarui bobot jaringan selama proses pelatihan.

2) Pelatihan Model

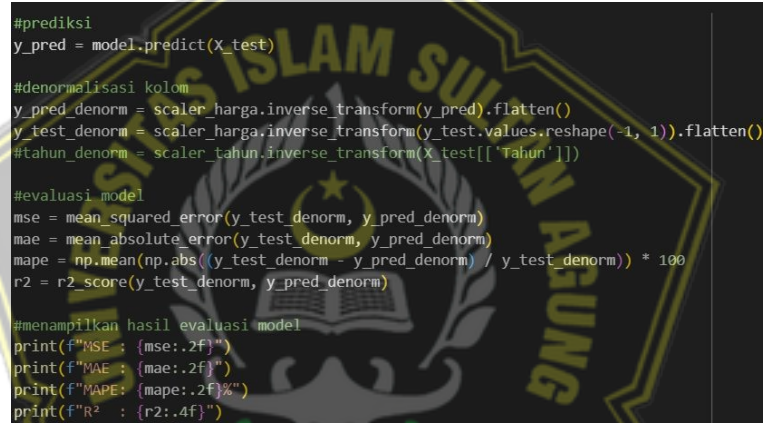
```
#pelatihan model
history = model.fit(X_train, y_train, validation_split=0.2, epochs=300, batch_size=32, verbose=0)
```

Gambar 4. 12 Pelatihan model

Gambar 4.12 merupakan skrip untuk proses pelatihan di mulai dengan fungsi `model.fit()` yang menjalankan proses pembelajaran jaringan syaraf tiruan berdasarkan input `X_train` dan target `y_train`. Dalam pelatihan ini, digunakan parameter `validation_split=0.2` yang berarti 20% dari data

pelatihan digunakan sebagai data validasi untuk memantau performa model pada data yang tidak dilatih secara langsung. Proses pelatihan dilakukan selama 300 epoch, di mana satu epoch merepresentasikan satu siklus penuh penggunaan seluruh data pelatihan. Setiap epoch dibagi menjadi mini-batch dengan ukuran 32 data (batch_size=32), yang bertujuan untuk mempercepat pelatihan dan menstabilkan pembaruan bobot. Parameter verbose=0 digunakan untuk menonaktifkan output log selama proses pelatihan. Seluruh informasi proses pelatihan disimpan dalam variabel history, yang kemudian dapat digunakan untuk menganalisis perkembangan nilai loss pada data pelatihan dan validasi di setiap epoch.

4.1.4 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 4. 13 Denormalisasi dan Evaluasi model

Setelah proses pelatihan selesai, model digunakan untuk melakukan prediksi terhadap data uji melalui perintah `model.predict(X_test)`, yang menghasilkan nilai prediksi dalam bentuk ter-normalisasi. Oleh karena itu, sebelum dilakukan evaluasi, seperti yang dilihat pada gambar 4.13 hasil prediksi (`y_pred`) dan nilai aktual (`y_test`) harus dikembalikan ke skala aslinya melalui proses denormalisasi menggunakan fungsi `inverse_transform()` dari objek `scaler_harga` yang telah disimpan sebelumnya. Nilai hasil prediksi (`y_pred_denorm`) dan nilai aktual (`y_test_denorm`) kemudian dibandingkan untuk menghitung performa model. Evaluasi dilakukan dengan beberapa metrik regresi, yaitu Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi (R^2).

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

Gambar 4. 14 Hasil evaluasi model

Hasil evaluasi model menunjukkan bahwa model ANN yang telah dibangun memiliki performa prediksi yang cukup baik. Nilai Mean Squared Error (MSE) sebesar 598 juta mengindikasikan bahwa rata-rata kuadrat selisih antara hasil prediksi dan nilai aktual cukup rendah, terutama jika dibandingkan dengan skala harga satuan yang berada dalam puluhan hingga ratusan ribu rupiah. Mean Absolute Error (MAE) sebesar 12.923,91 menunjukkan bahwa rata-rata kesalahan prediksi berada pada kisaran ± 13 ribu rupiah, yang secara praktis masih dapat diterima dalam konteks estimasi harga konstruksi. Nilai MAPE sebesar 24,68% menunjukkan bahwa secara rata-rata, prediksi model menyimpang sebesar 24,68% dari nilai aktual, yang berarti model masih memiliki ruang untuk peningkatan akurasi, terutama jika dihadapkan pada fluktuasi harga ekstrem. Namun demikian, nilai koefisien determinasi (R²) yang mencapai 0,9818 menandakan bahwa model mampu menjelaskan sekitar 98,18% variasi dalam data harga satuan pekerjaan berdasarkan fitur input yang digunakan.

Berikut adalah data uji/aktual dan data hasil pelatihan/prediksi :

Tabel 4. 1 Data aktual dan data prediksi

Tahun	Aktual (Rp)	Prediksi (Rp)	Error (Rp)	Error ² (Rp)	Error (Rp)	APE (%)
2024	13,629.69	30,483.73	16,854.04	284,058,614.3	16,854.04	123.66
2020	79,708.5	85,840	-6,131.5	37,595,292.25	6,131.5	7.69
2023	490,267.11	428,169.16	62,097.95	3,856,155,859.94	62,097.95	12.67
2021	11,429.83	12,687.65	-1,257.82	1,582,119.51	1,257.82	11
2019	348,744.24	348,091.28	652.96	426,355.13	652.96	0.19
2019	11,492.94	10,186.44	1,306.5	1,706,953.89	1,306.5	11.37
2024	35,118.78	37,285.39	-2,166.61	4,694,218.53	2,166.61	6.17

Tabel 4.1 pada kolom aktual merupakan data uji kemudian pada kolom prediksi

merupakan data hasil pelatihan. Terdapat kolom lain seperti :

- a) Kolom Error, merupakan kolom hasil selisih error antara nilai dari data aktual dan data prediksi, dengan contoh perhitungannya :

$$13,629.69 - 30,483.73 = -16,854.04$$

- b) Kolom $Error^2$, merupakan kolom hasil dari error kuadrat yang sumbernya dari kolom sebelumnya, dengan contoh perhitungannya :

$$16,854.04^2 : 16,854.04 \times 16,854.04 = 284,058,614.3.$$

- c) Kolom $|Error|$, merupakan kolom yang digunakan dalam perhitungan *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE), sama seperti kolom error, nilai nya dari selisih aktual dan prediksi bedanya adalah semua bilangan di kolom ini bernilai positif, contoh perhitungannya sebagai berikut :

$$13,629.69 - 30,483.73 = 16,854.04.$$

- d) Kolom APE %, digunakan untuk menghitung MAPE (*Mean Absolute Percentage Error*):

$$\text{Nilai aktual} : 13,629.69$$

$$\text{Nilai Prediksi} : 30,483.73$$

$$\text{Error} : 30,483.73 - 13,629.69 = 16,854.04$$

$$|Error| : 16,854.04$$

$$APE = \frac{16,854.04}{13,629.69} \times 100 = 123.66\%$$

Kemudian perhitungan secara detail dari metrik evaluasi regresi :

- 1) MSE (*Mean Squared Error*)

$$MSE = \frac{1}{n} \sum (Error)^2$$

- Langkah perhitungannya :

Tabel 4. 2 kolom error

Error ²
284,058,614
37595292.3
3856155860
1582119.51
426355.13
1706953.89
4694218.53

- Menjumlahkan nilai kolom $error^2$, sehingga :

$$= 284,058,614.29 + 37,595,292.25 + 3,856,155,859.94 + 1,582,119.51 + 426,35$$

$$5.13 + 1,706,953.89 + 4,694,218.53$$

$$= 4,186,219,413.52$$

$$MSE = \frac{4,186,219,413.52}{7} = 598,031,344.79$$

2) MAE (*Mean Absolute Error*)

$$MAE = \frac{1}{n} \sum |\text{Error}|$$

- Langkah perhitungannya :

Tabel 4. 3 kolom error

 Error
16854.04
6131.5
62097.95
1257.82
652.96
1306.5
2166.61

- Menjumlahkan nilai kolom |Error|, sehingga :

$$= 16,854.04 + 6,131.50 + 62,097.95 + 1,257.82 + 652.96 + 1,306.50 + 2,166.61$$

$$= 90,467.38$$

$$MAE = \frac{90,467.38}{7} = 12,923.91$$

3) MAPE (*Mean Absolute Percentage Error*)

$$MAPE = \frac{1}{n} \sum \left| \frac{\text{Error}}{\text{Aktual}} \right| \times 100$$

- Langkah perhitungannya :

Tabel 4. 4 kolom APE

APE (%)
123.66
7.69
12.67
11
0.19
11.37
6.17

- Menjumlahkan nilai kolom APE, sehingga :

$$123.66 + 7.69 + 12.67 + 11.00 + 0.19 + 11.37 + 6.17 = 172.75$$

$$MAPE = \frac{172.75}{7} = 24.68\%$$

4) R^2 (Koefisien Determinasi)

$$R^2 = 1 - \frac{\sum(Error)^2}{\sum(y_i - \bar{y})^2}$$

- Langkah perhitungannya :

Tabel 4. 5 Kolom Aktual

Aktual
13,629.69
79,708.5
490,267.11
11,429.83
348,744.24
11,492.94
35,118.78

- Pertama, hitung rata-rata dari nilai aktual ($\bar{y}$), sehingga :

$$\bar{y} = \frac{13,629.69 + 79,708.5 + 490,267.11 + 11,429.83 + 348,744.24 + 11,492.94 + 35,118.78}{7}$$

$$= \frac{990,391.09}{7} = 141,770.16$$

- Hitung total sum of squares (TSS) = jumlah kuadrat selisih antara nilai aktual dan rata-rata :

$$TSS = \sum (y_i - \bar{y})^2$$

- Hitung satu per satu

$$(13,629.69 - 141,770.16)^2 = 16,421,250,410.85$$

$$(79,708.50 - 141,770.16)^2 = 3,847,396,160.74$$

$$(490,267.11 - 141,770.16)^2 = 121,113,826,922.93$$

$$(11,429.83 - 141,770.16)^2 = 17,011,460,713.51$$

$$(348,744.24 - 141,770.16)^2 = 42,884,654,603.40$$

$$(11,492.94 - 141,770.16)^2 = 17,005,462,709.75$$

$$(35,118.78 - 141,770.16)^2 = 11,374,080,111.78$$


- Total TTS : 229,757,135,633.96

- Kemudian hitung sesuai rumus :

$$R^2 = 1 - \frac{4,185,219,413.54}{229,757,135,633.96} = 1 - 0.0182 = 0.9818$$

4.2 Visualisasi Performa Model

4.2.1 Grafik Loss Selama Epoch




Gambar 4. 15 Grafik loss selama epoch

Pada gambar 4.15 merupakan grafik yang menunjukkan perubahan nilai Loss (MSE) pada data pelatihan (Train Loss) dan data validasi (Val Loss) selama 300 epoch pelatihan model Artificial Neural Network (ANN). Terlihat bahwa pada awal pelatihan (sekitar epoch ke-1 hingga ke-30), nilai loss menurun secara signifikan. Setelah sekitar epoch ke-30, baik train loss maupun validation loss mengalami penurunan yang semakin landai dan mendekati angka nol, serta tetap stabil hingga akhir pelatihan (epoch ke-300). Kesesuaian antara kurva training dan validasi yang sangat dekat menunjukkan bahwa model tidak mengalami overfitting maupun underfitting. Tidak ada tanda-tanda divergensi antara loss pelatihan dan validasi, yang biasanya menjadi indikasi bahwa model telah belajar secara general dan seimbang terhadap data pelatihan dan data yang tidak dilatih langsung.

Oleh karena itu, grafik ini menguatkan temuan kuantitatif dari metrik evaluasi seperti MSE dan R^2 , dan menjadi bukti visual bahwa model ANN yang digunakan dalam penelitian ini telah dilatih dengan baik. Visualisasi loss ini tidak hanya berguna untuk memantau performa pelatihan, tetapi juga membantu peneliti dalam memastikan bahwa parameter pelatihan seperti jumlah epoch, ukuran batch, dan fungsi aktivasi telah dipilih secara tepat untuk mencapai performa model yang diinginkan.

4.2.2 Scatter Plot




Gambar 4. 16 grafik scatter plot

Pada gambar 4.16 menunjukkan grafik scatter plot yang menampilkan korelasi antara nilai aktual yang ditampilkan pada sumbu horizontal (x) dan hasil prediksi model yang ditampilkan pada sumbu vertikal (y). Titik-titik berwarna biru merepresentasikan pasangan antara data aktual dan nilai prediksi yang dihasilkan oleh model. Garis merah putus-putus yang memanjang secara diagonal menggambarkan garis referensi ideal, yaitu $y = x$ yang berarti prediksi model akan tepat sama dengan nilai aktual apabila semua titik berada pada garis.

Sebagian besar titik dalam grafik tampak berada di sekitar garis diagonal, yang menunjukkan bahwa prediksi model relatif akurat dan stabil dalam mencerminkan nilai yang sebenarnya. Meski demikian, terlihat adanya sedikit penyimpangan pada titik dengan nilai tinggi (sekitar 490.000), yang menunjukkan bahwa model masih mengalami sedikit ketidaktepatan dalam memprediksi nilai ekstrem, meskipun kesalahan tersebut masih tergolong dalam batas yang masih bisa diterima.

Dengan demikian, scatter plot ini mendukung hasil evaluasi kuantitatif seperti nilai R^2 yang tinggi dan MSE yang rendah, serta memperkuat kesimpulan bahwa model ANN yang dibangun memiliki daya prediksi yang cukup baik dan layak diterapkan dalam sistem estimasi harga satuan pekerjaan konstruksi jalan.

4.2.3 Histogram




Gambar 4. 17 grafik distribusi harga satuan

Pada gambar 4.17 merupakan grafik yang disajikan menggunakan histogram sebagai metode visualisasi untuk menampilkan distribusi frekuensi nilai harga satuan antara data aktual dan hasil prediksi. Dalam grafik ini, dua jenis distribusi ditampilkan, nilai aktual digambarkan dengan warna biru muda, sedangkan nilai prediksi divisualisasikan menggunakan warna oranye terang.

Berdasarkan hasil grafik, sebagian besar nilai harga satuan, baik dari data aktual maupun prediksi, terkonsentrasi pada kisaran harga rendah, yaitu di bawah Rp100.000. Hal ini terlihat dari tingginya batang histogram di sisi kiri grafik, yang menandakan bahwa sebagian besar pekerjaan jalan dalam dataset memiliki harga satuan pada level menengah ke bawah.

Perbedaan mulai tampak pada nilai-nilai yang termasuk ke dalam kategori harga tinggi, khususnya di atas Rp300.000. Dalam area ini, ditemukan beberapa perbedaan frekuensi antara data aktual dan hasil prediksi, di mana terdapat batang histogram oranye (prediksi) yang tidak memiliki padanan batang biru (aktual), atau sebaliknya. Ketidaksesuaian ini mengindikasikan adanya sedikit penyimpangan dalam hasil prediksi model terhadap nilai-nilai ekstrem atau outlier. Kendati demikian, perbedaan ini tidak terlalu signifikan dan tidak memengaruhi keseluruhan performa model dalam merepresentasikan distribusi data.

4.2.4 Perbandingan Harga Satuan Aktual dan Prediksi per Tahun




Gambar 4. 18 Perbandingan harga satuan aktuan dan prediksi

Pada gambar 4.18 merupakan grafik i menampilkan perbandingan antara nilai aktual dan hasil prediksi harga satuan pekerjaan pada berbagai tahun pengamatan. Sumbu horizontal (x) menunjukkan tahun (2019 hingga 2024), sedangkan sumbu vertikal (y) menunjukkan besarnya harga satuan dalam satuan rupiah. Kurva berwarna biru dengan titik bulat mewakili nilai aktual, sedangkan garis oranye putus-putus dengan penanda silang menunjukkan nilai prediksi yang dihasilkan oleh model Artificial Neural Network (ANN). Grafik ini digunakan untuk mengukur sejauh mana model mampu mengikuti tren harga satuan dari waktu ke waktu.

Secara keseluruhan, pola kurva prediksi menunjukkan kecenderungan mengikuti arah tren nilai aktual. Pada tahun-tahun seperti 2019, 2020, dan 2021, nilai yang diprediksi oleh model hampir sejajar dengan nilai sesungguhnya. Hal ini menunjukkan bahwa model ANN memiliki kapabilitas yang kuat dalam memahami pola historis serta memprediksi harga satuan pada periode yang fluktuasinya relatif stabil. Perbedaan yang lebih mencolok terlihat pada tahun 2023 dan 2024. Pada tahun 2023, prediksi model berada sedikit di bawah nilai aktual yang sangat tinggi, hampir menyentuh 500.000 rupiah, yang mengindikasikan bahwa model cenderung memberikan estimasi lebih rendah pada nilai ekstrem. Sedangkan pada tahun 2024, meskipun penurunan tren harga berhasil direplikasi oleh model, terdapat penyimpangan yang menunjukkan bahwa model masih belum sepenuhnya akurat dalam memproyeksikan nilai dengan harga sangat rendah.

4.2.5 Selisih Prediksi Terhadap Harga Aktual per Tahun



Gambar 4. 19 grafik selisih prediksi terhadap harga aktual

Pada gambar 4.19 terlihat grafik batang diatas menggambarkan sejauh mana perbedaan antara harga satuan aktual dengan hasil prediksi model pada masing-masing tahun. Sumbu horizontal mewakili rentang tahun dari 2019 hingga 2024, sementara sumbu vertikal menunjukkan nilai selisih yang dihitung dari pengurangan antara harga aktual dan harga yang diprediksi, dalam satuan rupiah. Setiap batang dalam grafik menunjukkan besar penyimpangan prediksi model terhadap nilai riil pada tahun terkait. Dari grafik tersebut, dapat diamati bahwa penyimpangan terbesar terjadi pada tahun 2023, dengan selisih melebihi Rp62.000, yang menunjukkan bahwa nilai prediksi model jauh lebih rendah dari nilai aktual. Hal ini menandakan bahwa model mengalami underestimasi untuk harga satuan yang tergolong tinggi, kemungkinan disebabkan oleh kurangnya data representatif pada kisaran nilai ekstrem selama proses pelatihan, sehingga model tidak mampu mempelajari pola dengan optimal.

Tahun 2024 menempati posisi kedua dengan selisih sekitar Rp17.000, yang juga menunjukkan kecenderungan model untuk memprediksi harga lebih rendah dari kenyataannya, meskipun tingkat penyimpangannya lebih kecil dibanding tahun sebelumnya. Sebaliknya, pada tahun-tahun seperti 2019, 2020, dan 2021, perbedaan antara nilai aktual dan hasil prediksi sangat kecil, yaitu kurang dari Rp7.000, yang mengindikasikan bahwa model mampu memberikan prediksi yang lebih akurat dan mendekati nilai sesungguhnya pada tahun-tahun dengan fluktuasi harga yang lebih stabil.

4.3 Deployment

4.3.1 Input Parameter Panjang, Lebar, Ketebalan, PPN



Sistem Prediksi Harga Satuan dan Estimasi Biaya Proyek Jalan

Input Parameter

Tahun
2026 - +

Panjang Jalan (meter)
100,00 - +

Lebar Jalan (meter)
5,00 - +

Ketebalan Jalan (meter)
0,10 - +

PPN (%)
0 11 20

Prediksi dan Hitung Estimasi

Gambar 4. 20 Tampilan input parameter

Pada gambar 4,20 terlihat tampilan utama user interface (UI) atau antarmuka untuk pengguna menginputkan parameter sebagai dasar untuk prediksi dan estimasi. Antarmuka dirancang dengan pendekatan interaktif dan intuitif, menggunakan input numerik dan slider agar mudah digunakan oleh pengguna. Beberapa fitur nya antara lain :

a) Input Tahun (Tahun Prediksi)

- Field pertama berisi input untuk tahun target, dalam contoh ini 2026.
- Tahun ini digunakan sebagai input ke dalam model Artificial Neural Network (ANN) untuk memprediksi harga satuan empat jenis pekerjaan jalan (LPA, pelaburan keras, burda, latasir).
- Tahun akan dinormalisasi secara internal sebelum diproses oleh model.

b) Panjang, Lebar, dan Ketebalan jalan

- Panjang Jalan (meter): Diisi dengan nilai 100 meter.
- Lebar Jalan (meter): Diisi dengan 5 meter.

- Ketebalan Jalan (meter): Diisi dengan 0,10 meter.
- Ketiga parameter ini digunakan untuk menghitung volume pekerjaan

c) PPN (%)


- Disediakan dalam bentuk slider interaktif, yang saat ini berada pada posisi 11%.
- Nilai ini digunakan dalam perhitungan estimasi akhir

d) Tombol “Prediksi dan Hitung Estimasi”

Setelah semua parameter diisi, pengguna dapat menekan tombol ini untuk menjalankan proses :

- Prediksi harga satuan berdasarkan tahun yang diinput
- Perhitungan estimasi biaya berdasarkan volume dan harga prediksi
- Penambahan PPN ke dalam total estimasi akhir

4.3.2 Tabel Hasil Prediksi dan Estimasi



	Jenis Pekerjaan	Satuan	Volume	Harga Satuan	Jumlah Harga
0	LPA	m ³	50.00	Rp 460,584.48	Rp 23,029,223.99
1	Pelaburan Keras	ltr	1,250.00	Rp 61,272.52	Rp 76,590,652.54
2	Burda	m ²	500.00	Rp 41,116.85	Rp 20,558,425.94
3	Latasir Manual	m ²	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 4. 21 Hasil prediksi dan estimasi

Pada gambar 4.21 terlihat tabel hasil prediksi harga satuan dan hasil estimasi keseluruhan. Komponen-komponen dalam tabel ini disajikan dalam lima kolom utama : Jenis Pekerjaan, Satuan, Volume, Harga Satuan, dan Jumlah Harga. Untuk kolom jenis pekerjaan ada 4 pekerjaan, berikut adalah penjelasan ber baris jenis pekerjaan :

a) LPA (Lapis Pondasi Agregat)

- Satuan : m³
- Volume : 50.00

Volume berasal dari panjang x lebar x ketebalan (100.00 m x 5,00 m x 0,10 m)

- Harga Satuan : Rp. 460,584.48

Harga satuan merupakan output prediksi yang berasal dari tahun yang diinputkan pengguna.

- Jumlah Harga : Rp. 23,029,223.99

Jumlah harga berasal dari harga satuan x volume (Rp. 460,584.48 x 50.00)

b) Pelaburan Keras

- Satuan : Ltr
- Volume : 1,250.00

Volume berasal dari panjang x lebar x 2,5 (100.00 m x 5.00 m x 2,5)

- Harga Satuan : Rp. 61,272.52

Harga satuan merupakan output prediksi yang berasal dari tahun yang diinputkan pengguna.

- Jumlah Harga : Rp. 76,590,652.54

Jumlah harga berasal dari harga satuan x volume (Rp.61,272.52 x 1,250.00)

c) Agregat Burda

- Satuan : m²
- Volume : 500.00

Volume berasal dari panjang x lebar (100.00 m x 5.00 m)

- Harga Satuan : Rp. 41,116.85

Harga satuan merupakan output prediksi yang berasal dari tahun yang diinputkan pengguna.

- Jumlah Harga : Rp. 20,558,425.94

Jumlah harga berasal dari harga satuan x volume (Rp.41,116.85 x 500.00)

d) Latasir Manual

- Satuan : m²
- Volume : 500.00

Volume berasal dari panjang x lebar (100.00 m x 5.00 m)

- Harga Satuan : Rp. 102,417.27

Harga satuan merupakan output prediksi yang berasal dari tahun yang diinputkan pengguna

- Jumlah Harga : Rp. 51,208,633.86

Jumlah harga berasal dari harga satuan x volume (Rp. 102,417.27 x 500.00)

Pada gambar 4.21 juga terdapat rekapitulasi perhitungan akhir, dimana ada total harga, ppn, total setelah ppn, dibulatkan dengan perhitungannya sebagai berikut :

- Total harga (Sebelum pajak) : Rp. 171,386,936.34

Total harga berasal dari dari penjumlahan kolom “Jumlah Harga”

- PPN (11%) : Rp. 18,852,563.00


Nilai persen PPN berasal dari *input*-an pengguna kemudian total ppn berasal dari total harga sebelum pajak x PPN 11% (171,386,936.34 x 0.11)

- Total harga (Setelah pajak) : Rp. 190,239,499.34

Total harga setelah pajak berasal dari total harga sebelum pajak + PPN (171,386,936.34 + 18,852,563.00)


- Dibulatkan : Rp. 190,239,400.00

Nilai pembulatan berasal dari kelipatan 100 terdekat kemudian dikurangi 100



4.3.3 Visualisasi Hasil Prediksi


1) Diagram Batang Harga Satuan per Jenis Pekerjaan



Gambar 4. 22 Grafik visualisasi harga satuan

Gambar 4.22 merupakan grafik batang yang secara jelas memperlihatkan bahwa Lapis Pondasi Agregat (LPA) merupakan jenis pekerjaan dengan biaya satuan tertinggi dibandingkan kategori lainnya, sehingga menjadi penyumbang utama dalam total anggaran proyek, khususnya jika volume pekerjaannya besar. Di sisi lain, pekerjaan seperti pelaburan keras dan burda memiliki harga satuan yang lebih rendah, namun tetap memiliki peran penting dalam akumulasi biaya keseluruhan, terutama bila cakupan area pekerjaan luas. Oleh karena itu, visualisasi harga satuan ini berperan penting dalam membantu pengguna maupun pengambil keputusan untuk mengidentifikasi komponen pekerjaan yang paling mempengaruhi total estimasi biaya dalam pelaksanaan proyek jalan.

2) Diagram Lingkaran Proporsi biaya per Jenis Pekerjaan



Gambar 4. 23 Diagram proporsi estimasi per jenis pekerjaan

Gambar 4.23 merupakan diagram pie yang memperlihatkan distribusi estimasi biaya proyek berdasarkan masing-masing jenis pekerjaan jalan yang diprediksi oleh sistem. Terdapat empat jenis pekerjaan yang dianalisis, yaitu Lapis Pondasi Agregat (LPA), Pelaburan Keras, Burda, dan Latasir Manual. Dari visualisasi tersebut, dapat diketahui bahwa Pelaburan Keras menjadi komponen biaya terbesar dengan porsi 44,7% dari keseluruhan anggaran, yang mengindikasikan bahwa walaupun harga per litemnya tidak terlalu tinggi, total volumenya yang besar menyebabkan akumulasi biaya meningkat signifikan. Selanjutnya, Latasir Manual memberikan kontribusi sekitar 29,9%, dipengaruhi oleh tingginya harga satuan serta luas area pekerjaan yang cukup besar. Sebaliknya, meskipun LPA memiliki nilai satuan tertinggi, total kontribusinya hanya 13,4%, karena volume pekerjaannya tergolong kecil. Sedangkan Burda menjadi kategori dengan proporsi paling rendah, yaitu 12%, disebabkan oleh harga satuan dan volume yang relatif lebih kecil. Secara keseluruhan, grafik ini menegaskan bahwa estimasi total biaya dipengaruhi oleh kombinasi antara harga satuan dan volume pekerjaan, bukan hanya berdasarkan mahalnnya satuan harga saja.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini berhasil mengimplementasikan sistem prediksi harga satuan pekerjaan jalan dan estimasi biaya proyek jalan berbasis web dengan memanfaatkan model Artificial Neural Network (ANN). 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. Namun, masih terdapat beberapa faktor yang mempengaruhi ketidakakuratan hasil prediksi, di antaranya adalah terbatasnya jumlah dan keragaman data. Meski begitu, sistem prediksi berhasil mendapatkan nilai prediksi harga satuan pekerjaan jalan ditahun mendatang yang bisa dijadikan acuan dalam pembuatan RAB (Rencana Anggaran Biaya).

5.2 Saran

Berdasarkan penelitian yang sudah ada dan faktor yang mempengaruhi kurangnya keakuratan data, penulis menyarankan untuk penelitian yang akan datang :

1. Menambah Jumlah dan Keragaman Data, Melakukan ekspansi data dengan menambahkan data harga satuan dari tahun-tahun sebelumnya atau daerah lain (misalnya kabupaten/kota se-provinsi) kemudian menyertakan variasi jenis proyek jalan (aspal, beton, pemeliharaan) agar model lebih mengenali pola umum dan tidak bias terhadap proyek spesifik.
2. Memasukkan variabel eksternal yang memengaruhi harga satuan, seperti : Indeks Harga Perdagangan Besar (IHPB) sektor konstruksi, Indeks Kemahalan Konstruksi (IKK), Inflasi tahunan (BPS), Harga rata-rata bahan baku (aspal, semen, batu split, BBM), Upah minimum kabupaten (UMK).

DAFTAR PUSTAKA

- Akbar, M. F., Handayani, T. N., & Saputra, A. (2024). *Pemodelan Artificial Neural Network Untuk Estimasi Biaya Proyek Peningkatan Jalan Aspal Dengan Variabel Bebas Dimensi Item Pekerjaan*.
- Al-Hawari, F., Al-Zu'bi, M., Barham, H., & Sararhah, W. (2021). The GJU Website Development Process And Best Practices. *Journal Of Cases On Information Technology (JCIT)*, 23(1), 21–48.
- Altalhoni, A., Liu, H., & Abudayyeh, O. (2024). Forecasting Construction Cost Indices: Methods, Trends, And Influential Factors. In *Buildings* (Vol. 14, Nomor 10). <https://doi.org/10.3390/Buildings14103272>
- Apriani, D. E., Siburian, G. B., Situmorang, R., Simamora, S. A., & Hutapea, T. A. (2025). Menyelesaikan Permasalahan Supremum Dan Infimum Suatu Himpunan Dengan Menggunakan Python. *Jurnal Media Akademik (JMA)*, 3(3).
- Bimantoro, A., Sumarno, S., & Tambunan, H. S. (2021). Estimasi Pemberantasan Hama Di Kebun Bah Jambi Menggunakan Algoritma Backpropagation. *Journal Of Computer System And Informatics (Josyc)*, 2(2), 222–231.
- Bintang, Y. K., & Imaduddin, H. (2024). Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(3), 1442–1455.
- 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 (JCEP)*, 2(2), 139–149.
- Dyer, R., & Chauhan, J. (2022). An Exploratory Study On The Predominant Programming Paradigms In Python Code. *Proceedings Of The 30th ACM Joint European Software Engineering Conference And Symposium On The Foundations Of Software Engineering*, 684–695.
- Ekpobimi, H. O., Kandekere, R. C., & Fasanmade, A. A. (2024). Conceptual Framework For Enhancing Front-End Web Performance: Strategies And Best Practices. *Global Journal Of Advanced Research And Reviews*, 2(1), 99–107.
- Fakhryza, K. A. (2024). *Penerapan Jaringan Syaraf Tiruan Untuk Peramalan Beban Dan Umur Transformator Pada Jaringan Sistem Tenaga Listrik 150 Kv*. Universitas Islam Sultan Agung Semarang.

- Farhana, R. (2025). *Pemodelan Prediksi Cuaca Menggunakan Artificial Neural Network (Ann) Berbasis Internet Of Things (Iot)*. UIN Ar-Raniry Banda Aceh.
- Fatomi, Z. S. (2021). *Pemrograman Dan Komputasi Numerik Menggunakan Python*. Ugm Press.
- Hrishikesh, C., & Patel, M. (2025). The Future Of No-Code And Low-Code Web Development. *International Research Journal Of Modernization In Engineering Technology And Science*, 07(3), 9651–9655.
- Mahamid, I. (2013). Conceptual Cost Estimate Of Road Construction Projects In Saudi Arabia. *Jordan Journal Of Civil Engineering*, 7(3), 285–294.
- Mukhtar, H., Rifaldo, M., Taufiq, R. M., & Rizki, Y. (2021). Peramalan Kedatangan Wisatawan Mancanegara Ke Indonesia Menurut Kebangsaan Perbulannya Menggunakan Metode Multilayer Perceptron. *Jurnal Coscitech (Computer Science And Information Technology)*, 2(2), 113–119.
- Nasution, R. (2024). Pengembangan Sistem Prediksi Kegagalan Mesin Berbasis AI Untuk Industri Manufaktur. *Jurnal Terapan Ilmu Pengetahuan*, 1(1), 47–51.
- Nugroho, P. A. (2023). Implementasi Jaringan Syaraf Tiruan Multi-Layer Perceptron Untuk Prediksi Penyinaran Matahari Kota Bandung. *Komputa: Jurnal Ilmiah Komputer Dan Informatika*, 12(1), 83–90.
- Pahlepi, M. R., & Huda, N. (2024). Implementasi Multilayer Perceptron Untuk Mendeteksi Kelayakan Minyak Goreng. *Jurnal Ilmiah KOMPUTASI*, 23(3), 365–372.
- Pradana, Y. A., Dewi, L. P., Pramudito, W., Fauzi, I. M., Negara, S. P. P. S., Iswari, D. A., Mudzakkir, M., & Handayani, T. (2023). Estimasi Harga Bawang Bawang Di Jawa Timur Menggunakan Model Multilayer Perceptron. *Jurnal Keilmuan Dan Keislaman*, 270–279.
- Pragana, D. A., Manurung, D. W., & Windarto, A. P. (2023). Analisa Metode Backpropagation Pada Prediksi Rata-Rata Harga Beras Bulanan Di Tingkat Penggilingan Menurut Kualitas. *Journal Of Computing And Informatics Research*, 2(3), 76–84.
- Rifky, M., Yuhandri, Y., & Sumijan, S. (2025). Prediksi Jumlah Kunjungan Pasien Pada Bidan Praktik Mandiri Dengan Jaringan Syaraf Tiruan Backpropagation. *Jurnal Komtekinfo*, 46–53.
- Soeharto, I. (1997). *Manajemen Proyek Dari Konseptual Sampai Operasional*. Erlangga.
- Sujjada, A., Ramdani, A. R., Kibtiyah, K., Utami, M. P., & Nullah, M. R. (2023).

Prediksi Nilai Ujian Sekolah Siswa SMK Plus Padjadjaran Berbasis Web Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Jurnal Informasi Dan Teknologi*, 151–158.

Tahapari, Y., Nugroho, A. S. B., & Suparma, L. B. (2021). Model Estimasi Biaya Dengan Cost Significant Model Dan Artificial Neural Network Proyek Peningkatan Jalan Aspal Di Yogyakarta. *Jurnal Teknik Sipil*, 16(2), 122–133.

Tondayana, Y. A., & Prayogo, D. (2024). The Implementation Of ANN In Predicting Construction Costs Considering Macroeconomic Factors: Penerapan Metode ANN Dalam Memprediksi Biaya Konstruksi Bangunan Dengan Mempertimbangkan Faktor Makroekonomi. *Dimensi Utama Teknik Sipil*, 11(2), 94–107.

Utomo, C., Indryani, R., Wiguna, I. P. A., Adi, T. J. W., Rohman, M. A., Rachmawati, F., Nurcahyo, C. B., & Putri, Y. E. (2023). Model Pelatihan Kelayakan Proyek Untuk UMKM Konstruksi Dalam Pengembangan Usaha. *Sewagati*, 7(3), 405–411.

ZAHIR, L. A., & MUHLIS, M. (2022). Jaringan Saraf Tiruan (Neural Network) Untuk Estimasi Produktivitas Pekerja Konstruksi. *Jurnal Daktilitas*, 2(2), 142–153.

Zhang, Z., Xing, Z., Xia, X., Xu, X., & Zhu, L. (2022). Making Python Code Idiomatic By Automatic Refactoring Non-Idiomatic Python Code With Pythonic Idioms. *Proceedings Of The 30th ACM Joint European Software Engineering Conference And Symposium On The Foundations Of Software Engineering*, 696–708.

