

Estimasi Biaya Perawatan Pasien Pengobatan Alternatif Patah Tulang Berdasarkan Prediksi Lamanya Sembuh dengan Model *Ensemble Learning*

Ghunyatullaami'ah¹, Budi Aribowo²

¹ Teknik Industri, Fakultas Sains dan Teknologi, Universitas Al-Azhar Indonesia, Jl. Sisingamangaraja Komplek Masjid Agung Al-Azhar Kebayoran Baru, Jakarta Selatan, 12110

***Email korespondensi:** budiaribowo@gmail.com

Received: 27 05 2026 – Revised: 29 07 2026 - Accepted: 04 08 2026 - Published: 05 08 2026

Abstrak. Pengobatan alternatif patah tulang masih menjadi pilihan utama bagi sebagian masyarakat. Namun, ketidakpastian dalam durasi penyembuhan dan total biaya yang harus dikeluarkan menjadi tantangan bagi pasien. Oleh karena itu, penelitian ini bertujuan mengembangkan model prediksi estimasi durasi penyembuhan dan biaya pengobatan menggunakan metode ensemble learning serta regresi linear. Penelitian ini, dua algoritma ensemble learning untuk memprediksi durasi penyembuhan berdasarkan berbagai faktor seperti usia pasien, jenis kelamin, jenis cedera, bagian cedera, dan tingkat kedatangan kontrol. Hasil penelitian menunjukkan bahwa model Gradient Boosting Ensemble Learning memberikan performa lebih baik dalam melakukan prediksi dengan R² Score 0,81 dibandingkan model Random Forest hanya menghasilkan R² Score 0,64. Setelah prediksi durasi penyembuhan diperoleh, regresi linear sederhana digunakan untuk mengestimasi total biaya pengobatan berdasarkan hubungan antara lama penyembuhan dan biaya total perawatan. Dengan adanya model prediksi kesembuhan dan persamaan regresi diperoleh, Total Biaya = $-172,800 + (181,100 \times \text{Prediksi Kesembuhan})$, dapat diperoleh estimasi biaya yang akurat, sehingga pasien dapat merencanakan keuangan dengan lebih baik dan penyedia layanan pengobatan alternatif dapat meningkatkan layanan secara lebih efektif dan berbasis data.

Kata kunci: alternative bone fracture treatment, ensemble learning, gradient boosting, random forest, regression

PENDAHULUAN

Pengobatan alternatif patah tulang tetap diminati, terutama di daerah dengan akses medis terbatas. Faktor budaya, biaya terjangkau, dan pengalaman turun-temurun mendukung popularitasnya (Rachman et al., 2020). Namun, tantangan utama bagi pasien adalah ketidakpastian durasi dan biaya pengobatan. Pengobatan alternatif merupakan metode penyembuhan di luar praktik kedokteran modern yang berkembang melalui *trial and error*. Metode ini menekankan pendekatan personal, kenyamanan, dan kebutuhan pasien (Kisa & Suraya, 2023). Pengalaman pasien berperan dalam menentukan pilihan pengobatan mereka. Ketidakpuasan terhadap hasil medis mendorong sebagian pasien beralih ke metode tradisional, sementara kesaksian pasien yang sembuh memperkuat kepercayaan masyarakat. Kemudahan akses menjadi faktor utama, karena metode ini tidak memerlukan prosedur administrasi yang rumit. Dibanding prosedur medis yang kompleks, pengobatan alternatif

lebih praktis dan tidak mengganggu aktivitas pasien serta keluarganya (Indarwati & Retni, 2021).

Teknologi kesehatan berkembang pesat, terutama dengan penerapan *machine learning* dalam analisis medis. *Machine learning* banyak digunakan dalam prediksi dan klasifikasi, seperti lama rawat inap, biaya perawatan, dan diagnosis penyakit. Penelitian menunjukkan bahwa algoritma ini mampu mengidentifikasi pola kompleks dengan akurasi lebih tinggi dibanding metode statistik tradisional. Keunggulan utama machine learning adalah kemampuannya beradaptasi dengan data baru, menjadikannya berguna dalam analisis data dan kecerdasan buatan tingkat lanjut (Wijoyo et al., 2024). Penelitian ini menerapkan metode *ensemble learning* untuk memprediksi durasi kesembuhan pasien berdasarkan variabel seperti usia, jenis kelamin, jenis cedera, bagian tubuh yang cedera, dan tingkat kedatangan pasien. *Ensemble learning* menggabungkan beberapa model untuk meningkatkan akurasi prediksi (Cendani & Wibowo, 2022).

Algoritma *Random Forest* dan *Gradient Boosting* digunakan karena efektif dalam menangani data kompleks. *Random Forest* membangun beberapa pohon keputusan secara acak untuk mengurangi risiko *overfitting* (Rayadin et al., 2024), sementara *Gradient Boosting* meningkatkan akurasi dengan memperbaiki kesalahan model sebelumnya (Dahlia et al., 2025). Kedua metode ini menghasilkan prediksi yang lebih baik dalam analisis data kesehatan. Evaluasi model menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *R² Score*. MAE mengukur kesalahan rata-rata (Putri & Arianto, 2024), MSE menghitung rata-rata kuadrat selisih prediksi dan nilai *actual* (Idris & Pontooyo, 2025), sementara *R² Score* menilai sejauh mana model dapat menjelaskan variasi data (Syahreza et al., 2024).

Model dengan akurasi tertinggi digunakan dalam analisis regresi untuk memprediksi total biaya perawatan. Regresi OLS menghasilkan estimator linear tidak bias terbaik (BLUE) jika memenuhi asumsi klasik, yaitu normalitas residual, homoskedastisitas, dan tidak adanya autokorelasi. Jika terpenuhi, estimasi parameter menjadi efisien, tidak bias, dan memiliki varians minimum (Agus, 2018).

MASALAH

Penelitian ini bertujuan untuk mendapatkan formulasi estimasi biaya perawatan pasien pengobatan alternatif patah tulang hingga dinyatakan sembuh.

METODE PELAKSANAAN

Penelitian ini dilakukan pada salah satu pengobatan alternatif di Jakarta, dengan menggunakan data rekam medis pasien yang mencakup variabel jenis kelamin, usia, jenis cedera, bagian tubuh yang cedera, serta tingkat kedatangan kontrol pasien. Selain itu, data biaya awal penanganan dan biaya kontrol rutin mingguan digunakan untuk mengestimasi total biaya perawatan pasien.

Data diolah menggunakan model Ensemble Learning dengan bantuan bahasa pemrograman Python. Proses diawali dengan preprocessing data, termasuk pembersihan dan transformasi data untuk memastikan kualitasnya. Selanjutnya, dilakukan prediksi durasi kesembuhan menggunakan algoritma Random Forest dan Gradient Boosting. Model dengan akurasi terbaik dipilih sebagai input dalam persamaan regresi linear sederhana untuk mengestimasi total biaya perawatan pasien. Dengan pendekatan ini, penelitian bertujuan menghasilkan model prediksi yang akurat serta estimasi biaya yang lebih terukur.

HASIL DAN PEMBAHASAN

Pengumpulan Data

Pada penelitian ini, data yang digunakan adalah data rekam medis pasien yang telah menjalani perawatan di salah satu pengobatan alternatif patah tulang di Jakarta Barat.

	Nama	Jenis_Kelamin	Usia	Penyakit	Bagian	Kontrol	Sembuh_Minggu	Biaya_Awal	Biaya_Kontrol	Total_Biaya
0	S*****	Perempuan	F	Patah	Paha	1.0	16	200000	185000	3160000
1	Y***	Perempuan	E	Geser	Ankle	0.9	10	150000	135000	1500000
2	Z****	Laki-laki	E	Patah	Selangka	1.0	10	150000	135000	1500000
3	D****	Laki-laki	D	Patah	Kaki	1.0	10	185000	150000	1685000
4	S****	Laki-laki	C	Patah	Paha	1.0	12	200000	185000	2420000
...	...	...	...	...	...	...	...	...	...	...
115	I****	Laki-laki	A	Patah	Tangan	1.0	6	150000	135000	960000
116	S****	Perempuan	D	Patah	Paha	1.0	11	200000	185000	2235000
117	H****	Laki-laki	A	Patah	Tangan	1.0	6	150000	135000	960000
118	A***	Laki-laki	D	Patah	Selangka	1.0	8	150000	135000	1230000
119	Z****	Laki-laki	A	Geser	Siku	1.0	8	150000	135000	1230000

Gambar 1. Data Rekam Medis Pasien

Data rekam medis berisikan variabel nama pasien, jenis kelamin pasien, usia pasien, jenis cedera tulang yang dialami pasien, bagian tubuh yang mengalami cedera, lama penyembuhan, dan tingkat kedatangan kontrol pasien setiap minggunya. Selain itu, terdapat data mengenai biaya awal penanganan dan biaya kontrol rutin yang harus dibayarkan tiap minggunya. Data rekam medis yang digunakan adalah data pasien dari bulan Mei-November 2024 yang telah dinyatakan sembuh.

Preprocessing Data

Preprocessing data adalah proses persiapan data sebelum digunakan dalam analisis atau pemodelan, yang mencakup beberapa tahap penting seperti pembersihan data, transformasi data, dan *encoding* data. Pembersihan data bertujuan untuk mengatasi nilai yang hilang, duplikasi, serta inkonsistensi agar data lebih akurat dan dapat diandalkan. Transformasi data dilakukan untuk mengubah format data agar lebih sesuai dengan kebutuhan analisis, seperti standarisasi. Sementara itu, encoding data diperlukan untuk mengonversi data kategori menjadi format numerik agar dapat diproses oleh algoritma *machine learning*.

```
import pandas as pd
from sklearn.preprocessing import LabelEncoder
file_path = r"C:\Users\Ghunya\tugasakhir.csv"
data = pd.read_csv(file_path)
data_cleaned = data.drop(columns=['Nama'])
print("Missing Values:\n", data_cleaned.isnull().sum())
data_cleaned.fillna(data_cleaned.median(numeric_only=True), inplace=True)
duplicate_rows = data_cleaned.duplicated().sum()
print(f"Jumlah data duplikat: {duplicate_rows}")
data_cleaned = data_cleaned.drop_duplicates()
print("Tipe Data Setelah Cleaning:\n", data_cleaned.dtypes)
data_cleaned.to_csv("tugasakhir_cleaned.csv", index=False)
data_cleaned.head()
```

Missing Values:

Jenis_Kelamin	0
Usia	0
Penyakit	0
Bagian	0
Kontrol	0
Sembuh_Minggu	0
Biaya_Awal	0
Biaya_Kontrol	0
Total_Biaya	0

dtype: int64

Jumlah data duplikat: 20

Tipe Data Setelah Cleaning:

Jenis_Kelamin	object
Usia	object
Penyakit	object
Bagian	object
Kontrol	float64
Sembuh_Minggu	int64
Biaya_Awal	int64
Biaya_Kontrol	int64
Total_Biaya	int64

Gambar 2. Pembersihan Data

Hasil pembersihan data menunjukkan bahwa tidak ada nilai yang hilang (*missing values*) dalam dataset setelah dilakukan pembersihan. Selain itu, terdapat 20 data duplikat yang telah diidentifikasi dan dihapus untuk memastikan keakuratan analisis. Setelah proses pembersihan, tipe data dalam dataset telah diperiksa. Beberapa kolom seperti "Jenis_Kelamin", "Usia", "Penyakit", dan "Bagian" masih dalam format *object*, sedangkan kolom numerik seperti "Sembuh_Minggu", "Biaya_Awal", "Biaya_Kontrol", dan "Total_Biaya" sudah dalam format *int64*. Hasil akhir dari preprocessing ini disimpan dalam file "tugasakhir_cleaned.csv" untuk digunakan dalam analisis selanjutnya. Proses ini memastikan bahwa data lebih bersih, bebas dari duplikasi, serta memiliki struktur yang lebih baik sehingga siap digunakan untuk eksplorasi dan analisis lebih mendalam terkait pengobatan alternatif patah tulang.

Proses transformasi data, variabel usia pasien dikategorikan ke dalam beberapa kelompok untuk menghindari terlalu banyak variasi dan mempermudah analisis. Pengelompokan ini didasarkan pada rentang usia tertentu, yaitu: kategori A untuk usia 5–11 tahun, kategori B untuk usia 12–17 tahun, kategori C untuk usia 18–24 tahun, kategori D untuk usia 25–44 tahun, kategori E untuk usia 45–60 tahun, dan kategori F untuk usia di atas 60 tahun.

	Nama	Jenis_Kelamin	Usia	Penyakit	Bagian	Kontrol	Sembuh_Minggu	Biaya_Awal	Biaya_Kontrol	Total_Biaya
0	S*****	1	5	2	6	1.0	16	200000	185000	3160000
1	Y***	1	4	0	0	0.9	10	150000	135000	1500000
2	Z****	0	4	2	9	1.0	10	150000	135000	1500000
3	D****	0	3	2	4	1.0	10	185000	150000	1685000
4	S****	0	2	2	6	1.0	12	200000	185000	2420000
...	...	...	...	...	...	...	...	...	...	...
115	I****	0	0	2	11	1.0	6	150000	135000	960000
116	S****	1	3	2	6	1.0	11	200000	185000	2235000
117	H****	0	0	2	11	1.0	6	150000	135000	960000
118	A***	0	3	2	9	1.0	8	150000	135000	1230000
119	Z****	0	0	0	10	1.0	8	150000	135000	1230000

Gambar 3. Encoding Data

Proses *encoding* data, variabel seperti jenis kelamin, usia pasien, jenis cedera tulang, dan bagian tubuh yang cedera diubah menjadi format numerik untuk mempermudah pemodelan ensemble learning. Untuk variabel jenis kelamin, kode 0 mewakili perempuan

dan 1 untuk laki-laki. Untuk usia, kategori A diberi kode 0, kategori B diberi kode 1, dan seterusnya hingga kategori F. Pada variabel jenis cedera tulang, kode 0 menunjukkan cedera geser, 1 untuk cedera retak, dan 2 untuk cedera patah. Sedangkan pada variabel bagian tubuh yang cedera, kode 0 digunakan untuk cedera pada bagian ankle, dan seterusnya untuk bagian tubuh lainnya.

Pengolahan Data

Setelah dataset siap untuk dilakukan pemodelan, dataset diolah menggunakan algoritma *Random Forest* dan *Gradient Boosting* pada *Ensemble Learning* untuk mendapatkan prediksi durasi kesembuhan dengan nilai akurasi yang paling baik.

```
X = data.drop(columns=['Sembuh_Minggu', 'Nama', 'Biaya_Awal', 'Biaya_Kontrol', 'Total_Biaya'])
y = data['Sembuh_Minggu']

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

model = RandomForestRegressor(
    n_estimators=100,
    max_depth=3,
    random_state=42
)

model.fit(X_train, y_train)
```

▼ RandomForestRegressor

RandomForestRegressor(max_depth=3, random_state=42)

Gambar 4. Algoritma Random Forest

Data diproses dengan memisahkan fitur (X) dan target (y), di mana fitur mencakup data seperti usia dan jenis kelamin, sementara target adalah lama penyembuhan pasien. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian guna memastikan evaluasi yang akurat. Model *Random Forest Regressor* dengan 100 pohon keputusan dan kedalaman maksimal 3 digunakan untuk menjaga keseimbangan antara kompleksitas dan akurasi. Setelah pelatihan, model siap memprediksi lama penyembuhan pasien berdasarkan data baru, mendukung pengambilan keputusan berbasis *ensemble learning*.

```
X = data.drop(columns=['Sembuh_Minggu', 'Nama', 'Biaya_Awal', 'Biaya_Kontrol', 'Total_Biaya'])
y = data['Sembuh_Minggu']

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

model = GradientBoostingRegressor(
    n_estimators=100,
    learning_rate=0.1,
    max_depth=3,
    random_state=42
)

model.fit(X_train, y_train)
```

▼ GradientBoostingRegressor
GradientBoostingRegressor(random_state=42)

Gambar 5. Algoritma Gradient Boosting

Data diproses dengan memisahkan fitur (X) dan target (y), di mana fitur mencakup informasi seperti usia dan jenis kelamin, sedangkan target adalah lama penyembuhan pasien. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian guna memastikan evaluasi yang akurat. Model dibangun dengan 100 pohon keputusan, *learning rate* 0.1, dan kedalaman maksimum 3 untuk mencegah *overfitting*. *Random state* ditetapkan agar hasil konsisten, lalu model dilatih menggunakan data pelatihan untuk mempelajari pola dan menghasilkan prediksi penyembuhan yang akurat.

Tabel 1. Perbandingan Akurasi Model

Model	MAE	MSE	R ² Score
<i>Random Forest</i>	1.13	2.21	0.64
<i>Gradient Boosting</i>	0.80	1.13	0.81

Hasil penerapan *Random Forest* dan *Gradient Boosting* menunjukkan bahwa *Gradient Boosting* lebih akurat. Hal ini terlihat dari nilai *Mean Absolute Error* (MAE) dan *Mean Squared Error* (MSE) yang lebih kecil, menandakan prediksi lebih mendekati nilai sebenarnya dengan variansi kesalahan yang lebih rendah. Selain itu, nilai *R² Score Gradient Boosting* lebih tinggi, menunjukkan kemampuannya yang lebih baik dalam menjelaskan variasi data target. Dengan demikian, *Gradient Boosting* lebih unggul dalam memprediksi lama penyembuhan pasien dibandingkan *Random Forest*.

Persamaan Regresi

Persamaan regresi digunakan untuk estimasi total biaya perawatan pasien yang harus dibayarkan hingga dinyatakan sembuh. Karena durasi kesembuhan pasien memengaruhi total biaya, input prediksi durasi kesembuhan menggunakan hasil dari model *Gradient Boosting*.

OLS Regression Results						
Dep. Variable:	Total Biaya	R-squared:	0.900			
Model:	OLS	Adj. R-squared:	0.899			
Method:	Least Squares	F-statistic:	1063.			
Date:	Mon, 03 Feb 2025	Prob (F-statistic):	7.50e-61			
Time:	15:39:06	Log-Likelihood:	-1586.6			
No. Observations:	120	AIC:	3177.			
Df Residuals:	118	BIC:	3183.			
Df Model:	1					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	-1.728e+05	4.89e+04	-3.530	0.001	-2.7e+05	-7.58e+04
Sembuh_Minggu	1.811e+05	5556.000	32.597	0.000	1.7e+05	1.92e+05
Omnibus:	45.157	Durbin-Watson:	2.160			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	100.866			
Skew:	1.536	Prob(JB):	1.25e-22			
Kurtosis:	6.277	Cond. No.	35.5			

Gambar 6. Hasil Regresi

Analisis regresi *Ordinary Least Squares* (OLS) menghasilkan persamaan estimasi biaya penyembuhan:


$$\text{Total Biaya} = -172,800 + (181,100 \times \text{Prediksi Kesembuhan})$$

Koefisien regresi menunjukkan bahwa setiap tambahan 1 minggu durasi penyembuhan meningkatkan total biaya sebesar Rp181.100, dengan konstanta negatif yang mengindikasikan biaya lebih rendah pada durasi penyembuhan mendekati nol. Nilai *R-squared* sebesar 0.9 menunjukkan bahwa 90% variasi total biaya dijelaskan oleh durasi penyembuhan, menandakan model yang akurat. Probabilitas F-statistik yang sangat kecil (7.50e-61) menunjukkan signifikansi model secara keseluruhan, sementara nilai $P > |t| < 0.05$

pada konstanta dan durasi kesembuhan mengonfirmasi bahwa kedua variabel ini signifikan dalam menjelaskan hubungan antara durasi penyembuhan dan total biaya.


Uji Asumsi Klasik Regresi Linear Sederhana

Regresi linear sederhana memerlukan pemenuhan asumsi klasik agar estimasi yang dihasilkan valid, tidak bias, dan efisien. Uji asumsi klasik dalam penelitian ini mencakup uji normalitas residual, uji heteroskedastisitas, dan uji autokorelasi. Uji normalitas memastikan bahwa residual terdistribusi normal untuk validitas uji statistik, sementara uji heteroskedastisitas mengevaluasi apakah variansi residual konstan. Uji autokorelasi dilakukan untuk memastikan tidak adanya pola hubungan antarwaktu pada residual. Dengan pemenuhan asumsi klasik, model regresi diharapkan mampu memberikan prediksi yang lebih akurat dan dapat diandalkan.



Gambar 7. Uji Normalitas

Plot uji normalitas menunjukkan bahwa histogram residual berdistribusi normal, meskipun terdapat sedikit penyimpangan yang mengindikasikan deviasi kecil dari normalitas. Pada QQ-Plot, titik-titik residual sebagian besar mengikuti garis diagonal, yang menandakan distribusi normal, tetapi terdapat sedikit penyimpangan yang menunjukkan bahwa residual tidak sepenuhnya normal. Namun, penyimpangan ini cenderung kecil, sehingga asumsi normalitas masih dapat diterima.



Gambar 8. Uji Heterokedastisitas

Hasil uji heteroskedastisitas menunjukkan model mengalami heteroskedastisitas yang mana variansi residual tidak konstan karena terlihat adanya pola peningkatan variasi residual pada nolai fitted yang lebih besar.

Uji autokorelasi dalam regresi linear sederhana bertujuan memastikan bahwa residual tidak memiliki pola tertentu berdasarkan urutan data, sehingga hasil model tetap valid dan akurat. Pengujian dilakukan menggunakan nilai Durbin-Watson, di mana rentang 1,5 – 2,5 menunjukkan tidak adanya autokorelasi. Hasil regresi menunjukkan nilai Durbin-Watson sebesar 2,16, yang mengindikasikan bahwa residual tidak memiliki autokorelasi, sehingga model regresi memenuhi asumsi ini.

KESIMPULAN

Berdasarkan hasil penelitian, model *Gradient Boosting* menunjukkan performa lebih baik dibandingkan *Random Forest* dalam memprediksi durasi kesembuhan pasien. Hal ini terlihat dari nilai *Mean Absolute Error* (MAE) sebesar 0,80, *Mean Squared Error* (MSE) sebesar 1,13, dan *R² Score* sebesar 0,81, yang menunjukkan prediksi lebih akurat dan stabil. Selain itu, model regresi linear sederhana berhasil dibangun untuk mengestimasi total biaya pengobatan dengan persamaan Total Biaya = -172,800 + (181,100 × Prediksi Kesembuhan), di mana hasil prediksi kesembuhan dari *Gradient Boosting* digunakan sebagai input. Nilai

R-squared sebesar 0.9 menunjukkan bahwa 90% variasi dalam total biaya dapat dijelaskan oleh durasi kesembuhan, menandakan bahwa model ini cukup akurat dalam mengestimasi biaya perawatan.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Bapak Budi Aribowo atas bimbingan, arahan, dan masukan yang sangat berharga dalam penelitian ini. Penghargaan juga diberikan kepada Pengobatan Alternatif Patah Tulang Jakarta Barat yang telah memberikan dukungan dalam bentuk data, fasilitas, dan sarana yang memungkinkan penelitian ini dapat terlaksana dengan baik. Kontribusi dan dukungan dari semua pihak sangat berarti dalam penyelesaian penelitian ini.

DAFTAR PUSTAKA

- Agus, A. (2018). Analisis Pengaruh Rasio-Rasio Keuangan Perbankan Terhadap Kinerja Perbankan. *Kreatif : Jurnal Ilmiah Prodi Manajemen Universitas Pamulang*, 6(4), 76–87. <https://doi.org/10.32493/jk.v6i4.y2018.p76-87>
- Cendani, L. M., & Wibowo, A. (2022). Perbandingan Metode Ensemble Learning pada Klasifikasi Penyakit Diabetes. *Jurnal Masyarakat Informatika*, 13(1), 33–44. <https://doi.org/10.14710/jmasif.13.1.42912>
- Dahlia, R., Fitriana, L. A., & Seimahuira, S. (2025). Analisis Algoritma Gradient Boosting Dalam Pengaruh Masyarakat Memilih Rumah Sewa. *Jurnal Manajemen Informatika Dan Sistem Informasi*, 8(1), 35–44. <https://doi.org/10.36595/misi.v8i1.1356>
- Idris, N. O., & Pontooyo, F. (2025). Evaluasi Model Machine Learning untuk Prediksi Harga Mobil dengan Perbandingan Ensemble dan Regresi Linear. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 4(1), 129–143. <https://doi.org/10.70340/jirsi.v4i1.181>
- Indarwati, A., & Retni, A. (2021). Faktor Faktor Yang Mempengaruhi Masyarakat Memilih Pengobatan Alternatif Dikecamatan Kota Barat Kota Gorontalo Universitas Muhammadiyah Gorontalo. *Zaitun (Jurnal Ilmu Kesehatan)*, 3(1). <https://journal.umgo.ac.id/index.php/Zaitun/article/view/1259>
- Kisa, N., & Suraya, R. S. (2023). Kafurui Sebagai Pengobatan Alternatif Patah Tulang pada Masyarakat Muna di Desa Liangkabori. *KABANTI : Jurnal Kerabat Antropologi*, 7(2), 328–352. <https://doi.org/10.33772/kabanti.v7i2.2414>
- Putri, E. R., & Arianto, D. B. (2024). Perbandingan Performa Algoritma Metode Bagging dan Boosting pada Prediksi Konsentrasi PM10 di Jakarta Utara. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 10(1), 72–81. <https://doi.org/10.25077/TEKNOSI.v10i1.2024.72-81>

- Rachman, A., Ilmi, B., & Mulyani, Y. (2020). Studi Fenomenologi Pengalaman Pasien Dalam Penanganan Patah Tulang Dengan Ba'urut. *Jurnal Keperawatan Suaka Insan (JKSI)*, 5(1), 164–174. <https://doi.org/10.51143/jksi.v5i1.231>
- Rayadin, M. A., Musaruddin, M., Saputra, R. A., & Isnawaty, I. (2024). Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki. *BIOS: Jurnal Teknologi Informasi Dan Rekayasa Komputer*, 5(2), 111–119. <https://doi.org/10.37148/bios.v5i2.128>
- Syahreza, A., Ningrum, N. K., & Syahrazy, M. A. (2024). Perbandingan Kinerja Model Prediksi Cuaca: Random Forest, Support Vector Regression, dan XGBoost. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 526–534. <https://doi.org/10.29408/edumatic.v8i2.27640>
- Wijoyo, A., Saputra, A. Y., Ristanti, S., Sya'Ban, S. R., Amalia, M., & Febriansyah, R. (2024). Pembelajaran Machine Learning. *OKTAL: Jurnal Ilmu Komputer Dan Sains*, 3(02), 375–380. <https://journal.mediapublikasi.id/index.php/oktal/article/view/2305>



© 2026 by authors. Content on this article is licensed under a Creative Commons Attribution 4.0 International license. (<http://creativecommons.org/licenses/by/4.0/>).