Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

PREDIKSI PENETAPAN TARIF PENERBANGAN MENGGUNAKAN AUTO-ML DENGAN ALGORITMA RANDOM FOREST

Ruli Herdiana
Universitas STEKOM, jl.Majapahit 605 Semarang, Jawa Tengah, Indonesia
email: ruliruliher21@gmail.com

Abstract

With so many airlines competing with each other, airlines are competing to become the consumer/market's main choice, but to achieve this, there is no airline strategy that can predict the price of airline tickets according to market needs. To meet the needs of airlines, we need a way to determine the price of airline tickets according to market needs with the help of the influence of technology and information. This research method was carried out using Google Collaboratory as a media to create a data model with the Random Forest, Logistic Regression and Gradient Boosting Regressor algorithms. In this study, the model that produced the highest R2 value and the lowest RMSE was a random forest with an R2 value of 83.91% and an RMSE of $175.9. However, from the three models, Random Forest got a change in accuracy of 1.96% to 85.87. To assist in predicting the determination of flight fares, airline companies can more easily and be alert to determine flight fares that are in accordance with the market. Therefore, Random Forest can be declared better than Logistic Regression and Gradient Boosting models. The Random Forest model that has been created can be used to predict in real-time using Machine Learning.

Keywords*: Machine learning, Algoritma Random Forest, AutoML, Prediksi Penetapan tarif, Penerbangan*

1. PENDAHULUAN

Perkembangan di bidang pariwisata menjadi sebuah daya tarik bagi seorang traveller yang ingin berkunjung dan menikmati wisata di seluruh dunia, dan dapat menjadi dampak positif di sektor penerbangan dan sektor pariwisata. Dengan adanya peran teknologi sangat banyak mempengaruhi segala bidang salah satunya pada penjualan tiket pesawat, hal tersebut menjadi keuntungan bagi penyedia jasa layanan perjalanan dalam memperjual-belikan tiket pesawat dengan tarif yang murah. Dengan banyaknya maskapai yang bersaing satu sama lain, maka maskapai berlomba untuk menjadi pilihan utama konsumen/pasar, namun untuk mencapai hal tersebut, belum ada strategi maskapai yang dapat memprediksi harga tiket pesawat sesuai dengan kebutuhan pasar. Untuk memenuhi kebutuhan maskapai, maka diperlukan suatu cara untuk menetapkan harga tiket pesawat sesuai kebutuhan pasar dengan bantuan pengaruh teknologi dan informasi.

Penelitian tentang memprediksi sebuah harga telah banyak dilakukan. Salah satunya penelitian [1]–[3] yang menggunakan algoritma regresi untuk memprediksi pergerakan harga saham menggunakan model *deep learning* dan *fuzzy neural network*. Penelitian [4] untuk memprediksi produksi padi petani dengan model *machine learning* dengan algoritma *decision tree technique* dan data *classification* dengan akurasi 81,6%, Sementara penelitian [5] memprediksi harga bitcoin menggunakan model *machine learning* dengan algoritma *random forest, XGBoost, Quadratic Discriminant Analysis* dan *Support Vector Machine* dengan dimensi sampel *machine learning techniques*.

Berdasarkan permasalahan yang telah disebutkan pada paragraf sebelumnya, maka penulis menyarankan untuk membuat sebuah model *Machine Learning* dengan menggunakan algoritma *Random Forest, Logistic Regression dan Gradient Boosting Regressor* sehingga pihak maskapai dapat memprediksi penetapan harga

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

tiket pesawat tepat berdasarkan kebutuhan konsumen atau pasar. Parameter yang digunakan dalam membuat sebuah model yaitu jenis pelayanan, rute penerbangan, durasi penerbangan dan pemberhentian tujuan pesawat tiap maskapai penerbangan. Dari model tersebut diambil algoritma dengan akurasi tertinggi yang akan digunakan untuk memprediksi penetapan tarif tiket pesawat yang akan dikonfigurasikan dengan *AutoML*. Dengan model ini diharapkan memperoleh hasil akurasi minimum di atas 83%.

2. METODE PENELITIAN

Metode penelitian ini dilakukan menggunakan media bantu *Google Colaboratory* untuk membuat sebuah model data dengan algoritma *Random Forest*, *Logistic Regression* dan *Gradient Boosting Regressor*. *Workflow* untuk pembuatan model algoritma yang digunakan dapat dilihat pada Gambar 1. Penelitian diawali dengan pengambilan dataset dari website *Kaggle* yaitu dataset dari *Flight Price Prediction* milik Anshi Gupta; Setelah dataset diunduh, setelah itu dilakukan pada tahap *pre-processing* yang didalamnya terdapat *Data Cleaning* dan *Feature Engineering*; Setelah tahapan *pre-processing* selesai, dilakukan di tahapan *Exploratory Data Analysis* (EDA); Dan ditahap terakhir yang dilakukan adalah Model Building tahapan ini terdiri dari pembuatan model untuk memprediksi penetapan harga tarif penerbangan dengan konfigurasi default hingga pembuatan model dengan bantuan *AutoML*.

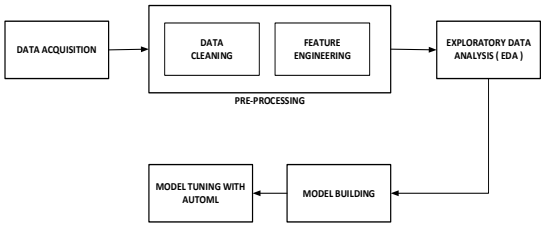

Gambar 1. Metode Penelitian

2.1 *Data Acquisition*

Penelitian ini, menggunakan dataset yang berasal dari repositori "*Flight Price Prediction*" milik Anshi Gupta di website Kaggle [6] agar proses pengambilan data dapat diproses. Dataset ini terdiri 11 kolom yang berisikan data hingga 10683 baris data. Tiap kolom merupakan informasi dari penerbangan seperti pada umumnya yaitu maskapai, tanggal keberangkatan, asal keberangkatan, kedatangan, rute penerbangan, jam keberangkatan, jam kedatangan, durasi penerbangan, dan total pesawat berhenti. Detail dari dataset "*Flight Price*" yang digunakan dapat dilihat pada Gambar 2.

	Airline	Date_of_Journey	Source	Destination	Route	Dep_Time	Arrival_Time	Duration	Total_Stops	Additional_Info	Price
0	IndiGo	24/03/2019	Banglore	New Delhi	BLR → DEL	22:20	01:10 22 Mar	2h 50m	non-stop	No info	3897
1	Air India	1/05/2019	Kolkata	Banglore	CCU → IXR → BBI → BLR	05:50	13:15	7h 25m	2 stops	No info	7662
2	Jet Airways	9/06/2019	Delhi	Cochin	DEL → LKO → BOM → COK	09:25	04:25 10 Jun	19h	2 stops	No info	13882
3	IndiGo	12/05/2019	Kolkata	Banglore	CCU → NAG → BLR	18:05	23:30	5h 25m	1 stop	No info	6218
4	IndiGo	01/03/2019	Banglore	New Delhi	BLR → NAG → DEL	16:50	21:35	4h 45m	1 stop	No info	13302

Gambar 2. Detail Dataset

2.2 *Data Cleaning*

Tahapan data cleaning berfungsi untuk melakukan proses persiapan menganalisis data yang tidak tepat atau tidak konsisten, dimana data tersebut memiliki pengaruh terhadap model yang akan dibuatkan. Data Cleaning memungkinkan lebih baik dalam pengumpulan data yang representatif untuk meningkatkan tingkat usability dataset yang digunakan dalam segi struktur dan kuliatas data [7]. Penelitian ini, terdapat nama pada kolom dataset yang digunakan untuk prediksi yang tepat dengan mengubah waktu dan tanggal, kolom dari Date_of_journey akan di ekstrak menjadi 2 kolom disimpan contoh data set saat data cleaning dapat dilihat pada Gambar 3 dan 4.

```
def change_into_datetime(col):
    df[col]=pd.to_datetime(df[col])
df.columns
Index(['Airline',     'Date_of_Journey',
'Source', 'Destination', 'Route',
       'Dep_Time',       'Arrival_Time',
'Duration', 'Total_Stops',
       'Additional_Info', 'Price'],
      dtype='object')
```

Gambar 3. Mengubah kolom Date_of_Journey

```
df['journey_day']=df['Date_of_Journey']
.dt.day
df['journey_month']=df['Date_of_Journey
'].dt.month
```


Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

```
df.drop('Date_of_Journey', axis=1,
inplace=True)
```

Gambar 4. Menghapus kolom Date_of_journey

2.3 *Feature Engineering*

Pada Tahapan Feature Engineering merupakan adalah proses mengekstraksi dan memanipulasi karakteristik dari data mentah. representasi numerik dari aspek data mentah berguna untuk membuat lebih banyak fitur atau kolom dari dataset yang telah ada agar terjadi peningkatan kinerja prediksi [8]. Pada penelitian ini, kolom Arrival_time and Dept_time features akan di ekstrak menjadi beberapa kolom baru, yaitu Dept_time_hour, Dept_time_min dan Arrival_time_hour, arrival_time_min. *Syntax* untuk *Feature Engineering* dapat dilihat pada Gambar 5.

```
# function for extracting hour and
minutes
def extract_hour(data,col):
    data[col+'_hour']=data[col].dt.hour

def extract_min(data,col):
   data[col+'_min']=data[col].dt.minute

def drop_col(data,col):
    data.drop(col,axis=1,inplace=True)

#call the function
# Departure time is when a plane
leaves the gate.
# Similar to Date_of_Journey we can
extract values from Dep_Time
extract_hour(df,'Dep_Time')

#extracting minutes
extract_min(df,'Dep_Time')

#drop the column
drop_col(df,'Dep_Time')


#extracting hour
extract_hour(df,'Arrival_Time')

#extracting min
extract_min(df,'Arrival_Time')

#drop the column
drop_col(df,'Arrival_Time')
```

Gambar 5. *Syntax Feature Engineering*

2.4 *Exploratory Data Analysis (EDA)*

Tahapan *Exploratory Data Analysis* (EDA) digunakan untuk fungsi dari statistik dan matematik divisualisaikan kedalam bentuk grafik, sehingga mempermudah pemahaman pola data yang ditampilkan. Selain itu, pendekatan tersebut digunakan untuk menganalisa, melihat, dan mencari *outliner* yang ada pada data untuk menarik kesimpulan dari karakteristik utamanya [9]. Pada penelitian ini, EDA dilakukan untuk melihat kolom dengan harga tarif penerbangan berdasarkan kategori data penerbangan. Visualisasi data menggunakan *library seaborn*. Grafik penerbangan terhadap harga berdasarkan rata-rata maskapai dapat dilihat pada Gambar 6, Grafik penerbangan terhadap harga berdasarkan total_stop dapat dilihat pada Gambar 7, Grafik penerbangan terhadap harga berdasarkan source dapat dilihat pada gambar 8, Grafik penerbangan terhadap harga berdasakan kategori destinasi dapat dilihat pada gambar 9.

.

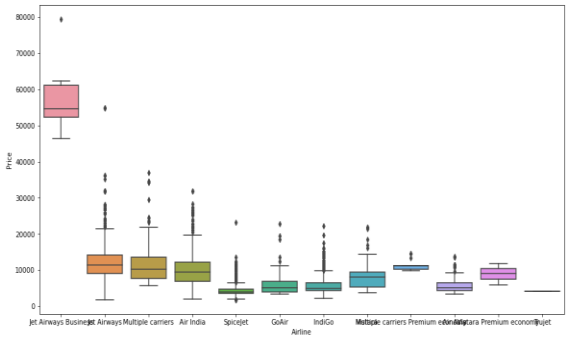

Gambar 2. Grafik Median Maskapai

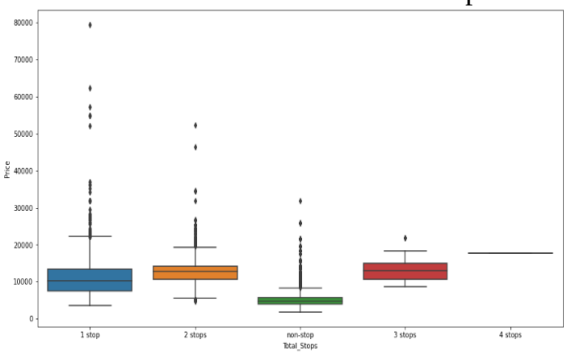

Gambar 3 Grafik total_stop

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

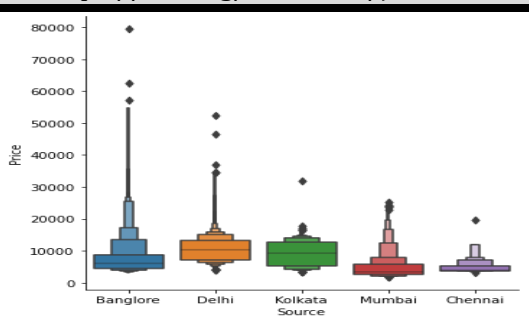

Gambar 4 Grafik Source

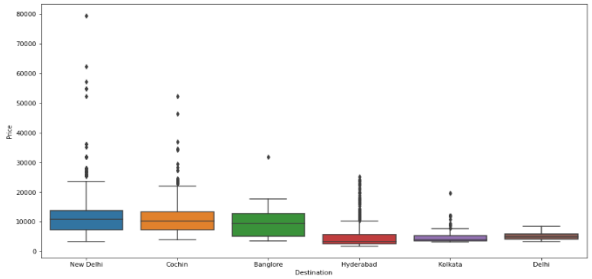

Gambar 5 Grafik destinasi

2.5 *Dataset Splitting*

Sebelum pembuatan kinerja model klasifikasi pada algoritma *Machine Learning*, dataset akan dipecah atau dipisahkan dua bagian menjadi data train-testing untuk menghindari *overfitting* [10]. Penelitian ini, konfigurasi yang digunakan untuk *dataset splitting* yang dipakai adalah 7:3, yaitu 70% dari dataset akan menjadi data *training*, sementara 20% dari dataset akan menjadi data testing. Proses *dataset splitting* dapat dilihat pada Gambar 10.

```
# spiliting the dataset
from sklearn.model_selection import train_test_split
X_train,X_test,y_train,y_test = train_test_split(X,y,test_size=0.20,random_state=123)
```

Gambar 10. Splitting Dataset

2.6 *Model Building*

Pada penelitian ini, untuk membentuk sebuah model *Machine Learning* yang bisa memprediksi penetapan tarif penerbangan, maka akan dipakai 3 jenis algoritma regressi pada umumnya dipakai dalam pemrosesan data, yaitu *Random Forest*, *Logistic Reggresi* dan *Gradient Boosting*.

2.7 *Hypertunning the model*

Pada penelitian ini, untuk pengujian nilai secara berulang digunakan untuk proses pelatihan sebuah dataset untuk mendapatkan nilai terbaik dari parameter yang ada. Hal tersebut menjadi poin penting tolak ukur pengujian dengan fitur lengkap dan terpilih [11]. Setelah pembuatan model selesai, maka akan dilakukan *hypertunning* untuk meningkatkan hasil akurasi model. *Hypertunning* model dilakukan sebagai berikut:

2.7.1. *Random Forest Regressor*

Random Forest adalah sebuah algoritma *Machine Learning* berbasis *Ensemble Learning* untuk proses klasifikasi dengan membentuk banyak *Decision Tree* untuk mendapatan proses *training*. Untuk sebuah nilai rata-rata dari prediksi yang dilakukan dari setiap *Tree* akan dilakukan [12]. Pada penelitian ini, algoritma *Random Forest* dibuat menggunakan konfigurasi estimator = 120, max_depth = auto dan max_features = 15. Proses Model Random Forest dapat dilihat pada Gambar 11.

```
rf=RandomForestRegressor()
rf_random=RandomizedSearchCV(estimator=
rf,param_distributions=random_grid,cv=3
,verbose=2,n_jobs=-1,)

rf_random.fit(X_train,y_train)
# best parameter
rf_random.best_params_
```

Gambar 11. Model Random Forest

2.7.2. *Logistic Regression*

Logistic regression adalah sebuah analisis model linier yang membentuk satu atau sebagian variabel bebas yang menghubungkan satu variabel dengan variabel lain untuk memprediksi dependent[13]. Penelitian ini, algoritma *Logistic Regression* dilakukan dengan konfigurasi default. Proses Model *Logistic Regression* dapat dilihat pada Gambar 12.

$$\pi(x) = \left[\frac{(g(x))}{1+(g(x)}\right]$$

$$\text{logit}[\pi(x)] = \ln\left[\frac{\pi(x)}{1-\pi(x)}\right] = g(x)$$

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

```
Model is: LogisticRegression()
Training score: 0.3356348741954359
Predictions are: [14571 15237 10844 ...
4226  7408 10262]

r2 score is: 0.44250914423182064
MAE:1872.6485727655593
MSE:10734864.158165652
RMSE:3276.4102548621186
```

Gambar 12. model *Logistic Regression*

2.7.3. Gradient Boosting Reggresor

Gradient Boosting Regressor sebuah teknik *machine learning* untuk mengatasi masalah dengan klasifikasi, algoritma ini telah terbukti berhasil memprediksi suatu masalah sehingga telah banyak digunakan dalam kompetisi *Kaggle*. Dalam tingkat akurasi, efesiensi, dan interprebilitas model tersebut mencapai kinerja muktahir setiap observasi *training* data [14-16]. Penelitan ini, algoritma *Gradient Boosting Regressor* dilakukan dengan konfigurasi default. Proses Model *Gradient Boosting Reggresor* dapat dilihat pada Gambar 13.

$$\{(x_i, \dot{y}_i)\}_{i=1}^{n}.$$

$$\frac{\sum Residual_i}{\sum[Prediksi\ Sebelumnya_i \times (1 - Prediksi\ Sebelumnya_i)}$$

```
Model is:
GradientBoostingRegressor()
Training score: 0.8004872305794601
Predictions   are:   [   5702.86974497
17826.76035345    12133.74946613    ...
4547.37535805
  6959.32889786 11428.58468176]

r2 score is: 0.8168061188758857
MAE:1397.4505612819867
MSE:3527522.3048542095
RMSE:1878.1699350309625
```

Gambar 13. Model *Gradient Boosting Regression*

3. HASIL DAN PEMBAHASAN

3.1. Akurasi Model

Penelitian ini menghasilkan sebuah model yang sudah dibentuk, maka komparasi dari model tersebut dapat dilakukan sehingga menghasilkan nilai dari setiap model. Penelitian ini, dikomparasi dari model *Random Forest, Logistic Regression, dan Gradient Boosting* nilai R2 dan *Real Mean Squared Error* (RMSE) Dapat dilihat pada Tabel 1.

Tabel 1. Komperasi Model

Model	R2 Score	RMSE
RF Regressor	83.91%	$175.9
Log Regressor	44.25%	$327.6
GB Regressor	81.68%	$187.8

Dari tabel diatas, dapat disimpulkan bahwasanya *Random Forest* memiliki nilai R2 tertinggi dan RMSE terendah. Maka *Gradient Boosting* dapat dinyatakan lebih baik dibanding algoritma lainnya untuk dipakai dalam hal memprediksi penetapan tarif penerbangan.

3.2. Feature Importance Model

Setelah proses pembuatan model variabel dilakukan, sebagai membantu pihak maskapai sewaktu menetapkan tarif penerbangan sesuai harga pasar, model bisa menjadi acuan menentukan tarif penetapan perbangan yang paling utama. Penelitian ini, bahwasanya dari ketiga algoritma yang dipakai menentukan penetapan tarif penerbangan bahwasanya Route2, Route3, dan Total_Stops adalah bagian fitur terpenting dalam penerbangan untuk penetapan tarif. Visualisasi untuk *Feature Importances* dapat dilihat pada Tabel 2.

Tabel 2. *Feature Importances*

	importance
Route2	2.773248
Route3	2.321282
Total_Stops	2.169140
Route1	2.080196
Arrival_Time_hour	1.874790
dur_hour	1.776536
Arrival_Time_min	1.563630
Delhi	1.547897
Cochin	1.531885
Route4	1.461545
Dep_Time_hour	1.418760
Dep_Time_min	1.217374
dur_min	1.084851

3.3. Prediksi Model

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

Jurnal Ilmu Komputer Ruru e-ISSN : 3046-3714
Volume 2 No 1 Januari 2025 | *pp :* 17-23
DOI : https://doi.org/10.69688/jikr.v2i1.10

Pada penelitian ini, informasi untuk melihat kinerja apakah model yang telah dibuat dapat memprediksi data valid dengan baik, maka dilakukan uji prediksi terhadap dataset validasi. Ketiga algoritma dipakai dan *scatter plot* akan dipakai untuk melakukan visualisasi prediksi. Visualisasi dapat dilihat pada Gambar 15.

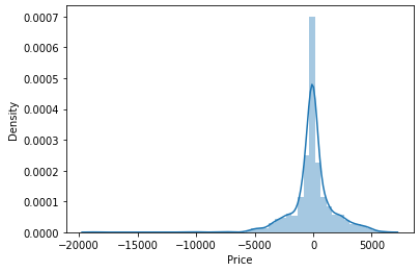

(a)

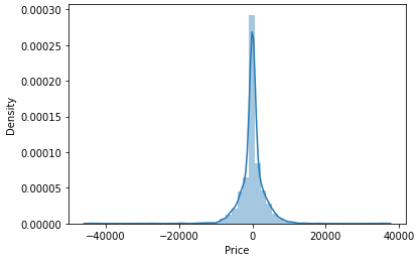

(b)

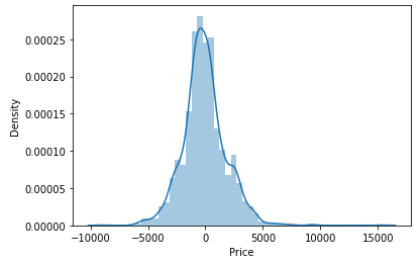

(c)

Gambar 15. Scatter Plot Model (a) Random Forest, (b) Logistic Regression, (c) Gradient Boosting

Pada visualisasi diatas, dapat dinyatakan dari ketiga model yang telah dibuatkan mendekati nilai harga asli pada dataset validasi. Maka, dari ketiga model telah dibuat juga dapat dipakai untuk melakukan prediksi penetapan tarif penerbangan.

4. KESIMPULAN

Untuk membantu dalam memprediksi penetapan tarif penerbangan, maka pihak perusahaan maskapai dapat lebih gampang dan waspada untuk menetapkan tarif penerbangan yang sesuai dengan pasar. Dalam penelitian ini, model yang dihasilkan nilai R2 tertinggi dan RMSE terendah adalah *Random Forest* dengan nilai R2 83.91% dan RMSE $175.9. Tetapi, dari ketiga model tersebut *Random Forest* mendapat perubahan akurasi sebesar 1,96% menjadi 85,87. Maka dari itu, *Random Forest* dapat dinyatakan lebih baik dari model *Logistic Regression* dan *Gradient Boosting*. Model *Random Forest* yang telah dibuat dapat dipakai untuk memprediksi secara *real-time* menggunakan *Machine Learning.*

5. REFERENSI

[1] B. M. Henrique, V. A. Sobreiro, and H. Kimura, “Stock price prediction using support vector regression on daily and up to the minute prices,” *J. Financ. Data Sci.*, vol. 4, no. 3, pp. 183–201, 2018, doi: 10.1016/j.jfds.2018.04.003.

[2] P. Yu and X. Yan, “Stock price prediction based on deep neural networks,” *Neural Comput. Appl.*, vol. 32, no. 6, pp. 1609–1628, 2020, doi: 10.1007/s00521-019-04212-x.

[3] U. Inyaem, “Construction Model Using Machine Learning Techniques for the Prediction of Rice Produce for Farmers,” *2018 3rd IEEE Int. Conf. Image, Vis. Comput. ICIVC 2018*, pp. 870–874, 2018, doi: 10.1109/ICIVC.2018.8492883.

[4] U. Inyaem, “Construction Model Using Machine Learning Techniques for the Prediction of Rice Produce for Farmers,” *2018 3rd IEEE Int. Conf. Image, Vis. Comput. ICIVC 2018*, pp. 870–874, 2018, doi: 10.1109/ICIVC.2018.8492883.

[5] Z. Chen, C. Li, and W. Sun, “Bitcoin price prediction using machine learning: An approach to sample dimension engineering,” *J. Comput. Appl. Math.*, vol. 365, 2020, doi: 10.1016/j.cam.2019.112395.

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**

[6] S. K. Singh and D. R. K. Dwivedi, "Data Mining: Dirty Data and Data Cleaning," SSRN Electron. J., 2020, doi: 10.2139/ssrn.3610772.

[7] S. K. Singh and D. R. K. Dwivedi, "Data Mining: Dirty Data and Data Cleaning," SSRN Electron. J., 2020, doi: 10.2139/ssrn.3610772.

[8] C. M. Sitorus, A. Rizal, and M. Jajuli, "Prediksi Risiko Perjalanan Transportasi Online Dari Data Telematik Menggunakan Algoritma Support Vector Machine," J. Tek. Inform. dan Sist. Inf., vol. 6, no. 2, pp. 254–265, 2020, doi: 10.28932/jutisi.v6i2.2672.

[9] R R. S. Oktavian and S. Budi, "Analisis Dataset Google Playstore Menggunakan Metode Exploratory Data Analysis," J. Strateg. Maranatha, vol. 2, no. 2, pp. 636–649, 2020.

[10] A. Nurhopipah and U. Hasanah, "Dataset Splitting Techniques Comparison For Face Classification on CCTV Images," vol. 14, no. 4, pp. 341–352, 2020.

[11] A. Ramdan, U. Siliwangi, N. Widyasono, U. Siliwangi, H. Mubarok, and U. Siliwangi, "Prediksi Jaringan TOR dan VPN menggunakan Algoritma K-Nearest Neighbour pada Trafik Darknet," vol. 05, no. 01, pp. 21–35, 2022.

[12] N. G. Ramadhan, F. D. Adhinata, A. Jala, T. Segara, and D. Putra, "Deteksi Berita Palsu Menggunakan Metode Random Forest dan Logistic Regression," vol. 9, no. 2, pp. 251–256, 2022, doi: 10.30865/jurikom.v9i2.3979.

[13] M. Nawawi, "Klasifikasi Tingkat Popularitas Siswa Berdasarkan Aktifitas Komunikasi Siswa Menggunakan Smartphone dengan Teknik Logistic Regression," vol. 4, no. 1, pp. 978–979, 2018.

[14] E. N. Fauziyah and S. R. Nudin, "Sistem Pendukung Keputusan Penentuan Jurusan di SMKN 1 Pungging Menggunakan Gradient Boosting Tree," vol. 3, pp. 42–50, 2021.

[15] Tamba, S.P., Tan, A.W., Gunawan, Y. and Andreas, A., 2021. Penerapan Data Mining Untuk Pembuatan Paket Promosi Penjualan Menggunakan Kombinasi Fp-Tree dan Tid-List. Jurnal Tekinkom (Teknik Informasi dan Komputer), 4(2), pp.201-211.

[16] Tamba, S.P., 2022. Prediksi Penyakit Gagal Jantung Dengan Menggunakan Random Forest. Jurnal Sistem Informasi dan Ilmu Komputer Prima (JUSIKOM PRIMA), 5(2), pp.176-181

Submitted: **16/02/2024**; Accepted: **10/01/2025**; Published: **31/01/2025**