

**Prediksi Harga Laptop Menggunakan Algoritma GRU dan BiLSTM****Elsina Novela Waroi<sup>1</sup>, Arief Setyanto<sup>2</sup>, Khusnawi<sup>3</sup>**<sup>1,2,3</sup> Universitas Amikom Yogyakarta, IndonesiaEmail: [elsinanovela@gmail.com](mailto:elsinanovela@gmail.com), [arief\\_s@amikom.ac.id](mailto:arief_s@amikom.ac.id), [khusnawi@amikom.ac.id](mailto:khusnawi@amikom.ac.id)**Abstract**

Pandemi COVID-19 yang dimulai pada awal tahun 2020 telah mengubah berbagai aspek kehidupan, terutama di Indonesia. Namun, implementasi WFH di Indonesia menghadapi beragam tantangan terkait infrastruktur teknologi, budaya organisasi, dan adaptasi karyawan. Sebanyak 32.37% usaha besar dan menengah menerapkan WFH secara parsial, dan 2.24% secara penuh pada tahun 2021. WFH juga dipicu oleh peningkatan polusi udara. Dalam WFH, perangkat kerja seperti laptop menjadi vital, tetapi fluktuasi harga laptop menimbulkan kebingungan dalam perencanaan anggaran pembelian. Metode penelitian yang digunakan adalah studi kualitatif melalui wawancara mendalam dengan perwakilan manajemen dan karyawan dari berbagai sektor industri. Prediksi harga laptop diperlukan untuk membantu masyarakat merencanakan anggaran secara akurat. Penelitian ini berfokus pada prediksi harga laptop menggunakan algoritma BiLSTM dan GRU dengan pendekatan cluster-then-predict. Berdasarkan evaluasi komparatif, model BiLSTM menunjukkan performa yang lebih baik dibandingkan GRU di sebagian besar cluster. Pada Cluster 3, BiLSTM memiliki nilai R<sup>2</sup> tertinggi sebesar 0.205 dan MAPE terendah sebesar 2.80%, menunjukkan prediksi yang lebih akurat dibandingkan GRU dengan R<sup>2</sup> sebesar 0.181 dan MAPE sebesar 2.72%. Untuk Cluster 1 dan Cluster 2, BiLSTM juga unggul dengan nilai R<sup>2</sup> masing-masing sebesar 0.066 dan 0.144 serta MAPE sebesar 3.01% dan 3.24%, sementara GRU memiliki nilai R<sup>2</sup> negatif (-0.031) di Cluster 1 dan 0.079 di Cluster 2 dengan MAPE sebesar 3.09% di kedua cluster. Secara keseluruhan, BiLSTM memberikan hasil prediksi yang lebih baik dibandingkan GRU.

**Kata Kunci: BiLSTM, GRU, Harga Laptop, Prediksi****Abstract**

*The COVID-19 pandemic, which began in early 2020, has changed many aspects of life, especially in Indonesia. However, the implementation of WFH in Indonesia faces various challenges related to technological infrastructure, organizational culture, and employee adaptation. As many as 32.37% of large and medium-sized enterprises implemented WFH partially, and 2.24% in full in 2021. WFH is also triggered by an increase in air pollution. In WFH, work devices such as laptops become vital, but fluctuations in laptop prices cause confusion in planning purchase budgets. The research method used is a qualitative study through in-depth interviews with management representatives and employees from various industry sectors. Laptop price predictions are needed to help people plan their budgets accurately. This research focuses on laptop price prediction using BiLSTM and GRU algorithms with a cluster-then-predict approach. Based on comparative evaluation, the BiLSTM model shows better performance than GRUs in most clusters. In Cluster 3, BiLSTM has the highest R<sup>2</sup> value of 0.205 and the lowest MAPE of 2.80%, indicating a more accurate prediction than GRU with an R<sup>2</sup> of 0.181 and a MAPE of 2.72%. For Cluster 1 and Cluster 2, BiLSTM also excelled with R<sup>2</sup> values of 0.066 and 0.144 and MAPE of 3.01% and 3.24%, respectively, while GRU had negative R<sup>2</sup> values (-0.031) in Cluster 1 and 0.079 in Cluster 2 with MAPE of 3.09% in both clusters. Overall, BiLSTM provides better prediction results than GRU.*

**Keywords: BiLSTM, GRU, Laptop Price, Prediction**

## PENDAHULUAN

Pandemi COVID-19 yang telah terjadi semenjak awal tahun 2020 telah memberikan dampak yang cukup besar terhadap kehidupan bermasyarakat di dunia khususnya di Indonesia. Di masa pandemi, pelaku bisnis melakukan aktivitas dengan meminta karyawan untuk tetap produktif dengan menyelesaikan pekerjaan dari rumah atau yang biasa disebut *work from home* (WFH) (Widjaja, Ashadi, & Cornellia, 2021).

Pada tahun 2021 sebanyak 32.37% pelaku usaha besar dan menengah (UMB) melakukan kegiatan WFH, dimana kegiatan tersebut dilakukan secara parsial dalam 1 minggu dan 2.24% dilakukan secara penuh (Siburian, Sitompul, & Sinurat, 2022). Hal lain yang memicu terjadinya WFH karena polusi udara yang memburuk (Salsabilla, 2023). Dalam menunjang pekerjaan secara WFH diperlukan *work device* yaitu laptop yang memadai. Akan tetapi, harga laptop sering mengalami perubahan yang membuat masyarakat bingung untuk menyiapkan dana estimasi yang diperlukan membeli laptop. Selain itu, dibutuhkan cara agar masyarakat dapat mengantisipasi pembelian laptop dengan harga yang terlalu mahal berdasarkan jenis maupun spesifikasi laptopnya. Oleh karena itu, untuk mengatasi permasalahan tersebut diperlukan prediksi. Prediksi menunjukkan apa yang akan terjadi pada suatu keadaan tertentu dan merupakan *input* bagi proses perencanaan dan pengambilan keputusan (Kafil, 2019).

Penelitian terkait prediksi dilakukan oleh (Siburian, Sitompul, & Sinurat, 2022) melakukan prediksi harga laptop menggunakan algoritma *Random Forest Regressor*, GBR dan XGBoost yang dimana algoritma tersebut dievaluasi menggunakan metode  $R^2$ . Hasil penelitian menyatakan bahwa algoritma XGBRegressor memiliki nilai 92.77% yang menjadikan metode tersebut terbaik antar keduanya.

Penelitian yang dilakukan oleh (Afrianto, Fudholi, & Rani, 2021) melakukan prediksi harga saham menggunakan BiLSTM dengan faktor sentiment publik. Saham adalah investasi yang menarik karena mampu memberikan tingkat keuntungan yang besar. Investor saham berusaha memilih perusahaan investasi yang baik untuk mendapatkan keuntungan dengan resiko relatif kecil. Oleh sebab itu, para investor saham perlu memiliki ketelitian dan melakukan penilaian terhadap suatu perusahaan. Hasil penelitian menunjukkan bahwa metode BiLSTM menghasilkan nilai MSE terkecil 0.094 dan nilai RMSE terkecil 0.306.

Penelitian yang dilakukan oleh (Puteri, 2023) melakukan prediksi harga saham Syariah menggunakan metode LSTM dan BiLSTM. Saham syariah diluncurkan pertama kali di Indonesia dan dapat diketahui bahwa harga pada saham tidak selalu stabil atau dapat mengalami kenaikan maupun penurunan. Bagi para investor diperlukan strategi dalam memprediksi harga saham agar dapat mengambil keputusan yang tepat dalam berinvestasi. Hasil pengujian menunjukkan bahwa metode BiLSTM menghasilkan nilai MAPE untuk setiap saham yaitu 2,59%, 1,77%, dan 1,05%, model tersebut termasuk dalam kategori sangat akurat.

Penelitian yang dilakukan oleh (Carnegie & Chairani, 2023) melakukan perbandingan metode LSTM dan GRU untuk prediksi curah hujan. Banyak faktor yang menyebabkan hujan lebat sehingga prediksi intensitas curah hujan yang dikeluarkan oleh BMKG merupakan solusi awal untuk melakukan perencanaan dan tindakan dalam menanggulangi dampak bencana alam. Hasil penelitian evaluasi nilai RMSE 16.81, MSE 282.55 dan MAD 10.43 diketahui bahwa nilai model LSTM 1 dengan pembagian dataset 7:3 memiliki performa terbaik dalam memprediksi curah hujan sedangkan untuk prediksi terjadinya hujan model GRU 1 dengan dataset 7:3 memiliki performa terbaik dengan nilai akurasi 62%, *precision* 58%, *recall* 66%, dan *f1-score* 62%.

Berdasarkan uraian diatas, maka dalam penelitian ini akan melakukan prediksi harga laptop dengan dataset “*Laptop Price*” yang diunggah oleh Muhammet Varli dan pernah digunakan oleh penelitian yang dilakukan (Siburian, Sitompul, & Sinurat, 2022) dan (Manegopale, Nerpagar, Sawant, Shinde, & Chandarkar, 2023). Pemilihan dataset ini bertujuan untuk mengetahui bagaimana performa yang dilakukan dengan menggunakan metode *cluster-then-predict* terhadap dataset, serta kedua penelitian tersebut hanya memanfaatkan model regresi model *machine learning*. Pada penelitian ini, model yang diajukan berusaha untuk menyelesaikan dengan awalan pengelompokkan yang dilakukan regresi. Pada dataset yang digunakan terdapat beberapa feature yang bersifat categorical, BiLSTM sendiri biasanya sering digunakan dalam dataset yang bersifat series dan *feature numeric type*. Namun dalam penelitian yang dilakukan (Pan, Liao, & Liang, 2022) menggunakan *categoric type* menyatakan, hasil yang didapatkan dapat menurunkan nilai RMSE yang diberikan. Pada penelitian ini juga menyatakan arsitektur juga mempengaruhi performa BiLSTM yang dapat naik dan turun.

Algoritma yang digunakan dalam penelitian ini adalah GRU dan BiLSTM, *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) adalah jenis *recurrent neural networks* (RNN) yang dikembangkan untuk mengatasi masalah gradient yang menghilang (*vanishing gradient*) pada RNN tradisional (Kristiana & Miyanto, 2023). Kedua algoritma tersebut dirancang untuk permasalahan yang bersifat series atau data yang bersifat urutan, hal ini dibuktikan oleh penelitian yang dilakukan (Shi, 2023) yang membandingkan kedua data (*series* dan *non-series*). Pemilihan BiLSTM dari LSTM didasari dari kelemahan model LSTM yang hanya membaca data secara kiri ke kanan. BiLSTM yang menutupi kelemahan tersebut menjadi salah satu pertimbangan BiLSTM dipilih. Data series adalah data yang disusun berdasarkan urutan waktu yang dimana data tersebut memiliki pola atau tren (Jose, 2022), sedangkan non-series data yang tidak memiliki komponen waktu dan digunakan untuk membantu identifikasi pola secara statistik (Geekyanage, Tunkiel, & Sui, 2021).

### **Artificial Intelligence**

*Artificial intelligence* atau AI merupakan salah satu teknologi yang sedang populer saat ini. Berbagai bidang industri sudah memanfaatkan teknologi tersebut, mulai dari kesehatan, keuangan dan lain-lain. Tidak hanya itu saja, AI juga sudah banyak diterapkan di kehidupan sehari-hari seperti untuk berkomunikasi, menemukan lokasi dan lain-lain. AI adalah sistem komputer yang mampu melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia. Teknologi ini dapat membuat keputusan dengan cara menganalisis dan menggunakan data yang tersedia di sistem. Proses yang terjadi dalam AI mencakup *learning*, *reasoning*, dan *self-correction* (Lubis, 2021).

### **Data Mining**

Data mining merupakan penggabungan dari beberapa disiplin ilmu yang dimanfaatkan untuk menggali informasi dari sekumpulan data. Informasi yang diperoleh selanjutnya dapat dimanfaatkan dalam proses penarikan kesimpulan, manajemen informasi, pengendalian proses dan sebagainya (Sartika & Saluza, 2022).

Data mining memiliki fungsi mencari pengetahuan yang bermanfaat dari sekumpulan data yang banyak. Data mining terdapat 5 peran utama yaitu Estimasi, *Forecasting*, Klasifikasi, Klastering dan Asosiasi (Ubaedi & Djaksana, 2022):

### **Prediksi**

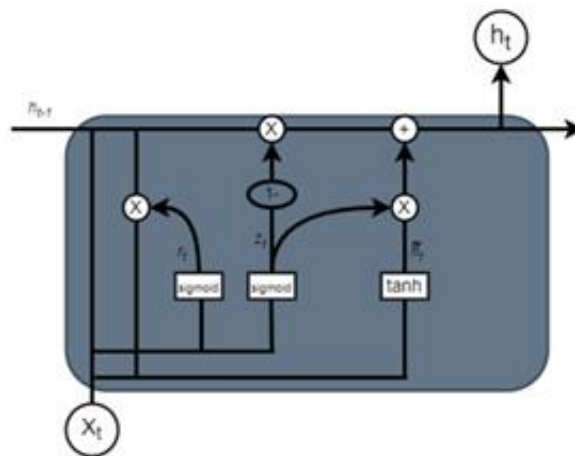
Prediksi yaitu sebuah peramalan atau perkiraan mengenai sesuatu yang akan terjadi secara pola

pikir dalam diri manusia. Prediksi akan terjadi jika didasari oleh informasi pada masa sebelum terjadi prediksi dan tujuan dari prediksi yaitu melakukan tindakan yang diperlukan untuk bersiap menghadapi sesuatu yang akan terjadi (Muhayat, Jayanta, & Chamidah, 2022).

Peramalan (*forecasting*) adalah suatu prosedur untuk membuat informasi factual tentang situasi sosial masa depan atas dasar informasi yang telah ada tentang masalah kebijakan. Ramalan mempunyai tiga bentuk utama: proyeksi, prediksi, dan perkiraan (Kafil, 2019).

### Algoritma GRU

GRU menggunakan 2 (dua) gate yaitu *Update Gate* dan *Reset Gate* untuk memutuskan informasi apa yang dapat diteruskan pada *output*. kedua bagian tersebut dapat dilatih untuk menyimpan informasi terdahulu tanpa harus membuang atau menghapus informasi yg tidak berhubungan dengan prediksi (Carnegie & Chairani, 2023).



Gambar 2. Arsitektur GRU

#### Reset Gate

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \tag{1}$$

$$\tilde{h}_t = \tanh(W_h[r_t * h_{t-1}, x_t] + b_h) \tag{2}$$

#### Update Gate

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \tag{3}$$

$$\tilde{h}_t = \tanh(W_h[z_t * h_{t-1}, x_t] + b_h) \tag{4}$$

Keterangan:

$x_t$ : Input vektor

$h_t$ : Output vektor

$h_{t-1}$ : Hidden state vector

$\tilde{h}_t$ : Kandidat aktivasi vektor


$\sigma$ : Fungsi Sigmoid

$\tanh$ : Fungsi *hyperbolic tangent*

$W_r, b_r, W_z, b_z$ : Pembobotan matriks

### Algoritma BiLSTM

*Bidirectional Long Short Term Memory* (BiLSTM) terdapat dua jaringan LSTM dimana jaringan LSTM pertama berfungsi dalam memproses urutan masukan data ke arah depan (*forward*) dan jaringan LSTM kedua berfungsi dalam memproses urutan data dari arah sebaliknya (*backward*). Kemudian *output* dari jaringan LSTM *forward* dan *backward* digabungkan pada setiap urutan waktu. Dengan adanya dua *layer* yang berlawanan arah tersebut, model dapat mempelajari informasi masa lalu dan informasi masa mendatang untuk setiap *sequence input* (Puteri, 2023).



Gambar 1. Arsitektur *Bidirectional Long Short-Term Memory* (BiLSTM)

Dalam arsitektur BiLSTM, proses pada *forward* LSTM dapat ditulis sebagai  $\vec{h}_t = LSTM(x_t, h_{t-1})$  sedangkan untuk proses *backward* LSTM ditulis sebagai  $\overleftarrow{h}_t = LSTM(x_t, h_{t+1})$ . *Output* akhir dari BiLSTM adalah penggabungan dari *forward* dan *backward* yang ditulis sebagai  $h_t = [\vec{h}_t, \overleftarrow{h}_t]$ .

### Koefisien Determinasi ( $R^2$ )

Koefisien Determinasi ( $R^2$ ) merupakan ukuran statistic yang menunjukkan pengaruh yang diberikan variabel bebas / independent (X) terhadap variabel terikat atau dependent (Y) (Putra & Juarna, 2021). Koefisien determinasi digunakan untuk menafsir kelayakan model dengan rentang nilai dari koefisien determinasi adalah  $0 \leq R^2 \leq 1$  (Sari, Gunawan, Adhigiadany, & Lisanthoni, 2023). Dimana semakin besar atau mendekati nilai 1 maka semakin kuat hubungan antara variabel bebas (X) dengan variabel terikat (Y). Sebaliknya apabila koefisien determinasi nya bernilai nol atau mendekati 0 maka semakin lemah atau tidak terdapat hubungan antara variabel bebas (X) dengan variabel terikat (Y) (Putra & Juarna, 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{1}$$

Dimana nilai  $y$  merupakan variabel terikat nilai asli,  $\hat{y}$  merupakan variabel terikat nilai prediksi, dan  $\bar{y}$  merupakan mean dari nilai  $y$ . Interpretasi koefisien determinasi dapat dilihat pada Tabel 1. (Maharadja, Maulana, & Dermawa, 2021).

Tabel 1. Interpretasi Koefisien Determinasi

Interval Koefisien	Tingkat Hubungan
0,80 – 1,000	Sangat Kuat
0,60- 0,799	Kuat
0,40 – 0,599	Cukup Kuat
0,20 – 0,399	Rendah
0,00 – 0,199	Sangat Rendah

**MAPE**

Mean Absolute Percentage Error (MAPE) merupakan nilai absolut dari persentase error data terhadap nilai rata-rata. MAPE adalah perhitungan yang digunakan untuk mengukur akurasi dari sistem prediksi (Yunizar, Rismawan, & Midyanti, 2023). Tahapan evaluasi diperlukan untuk menghitung seberapa baik sistem dalam memprediksi harga laptop.

$$M = \frac{\sum_{i=1}^n \frac{|(y_i - T_i)|}{T_i}}{n} * 100 \tag{2}$$

Keterangan:

M = error MAPE

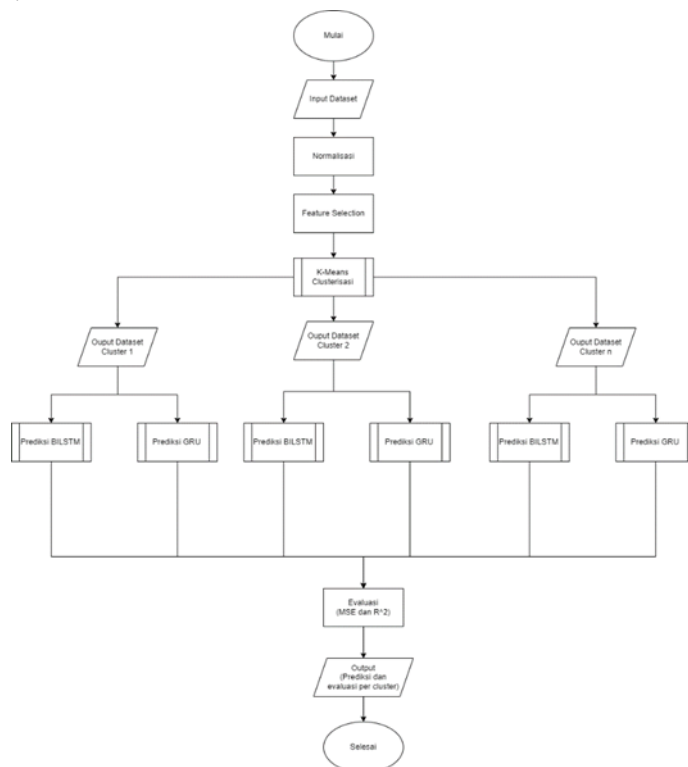
n = total banyak data

Y = nilai output hasil denormalisasi

T = target

**METODE PENELITIAN**

Pada penelitian ini, peneliti menggunakan algoritma GRU dan BiLSTM untuk memprediksi harga laptop. Data yang digunakan adalah dataset "Laptop Price" yang diunggah oleh Muhammet Varli, yang juga telah digunakan dalam penelitian sebelumnya oleh Sibirian, Sitompul, & Sinurat (2022) serta Manegopale et al. (2023). Dataset ini mencakup berbagai fitur laptop yang bersifat kategorikal dan numerik. Peneliti membagi data tersebut menjadi dua bagian: data training dan data testing, untuk menguji performa algoritma yang digunakan. Penelitian ini mengikuti alur yang ditunjukkan pada gambar 4 di bawah ini:





**Gambar 4. Alur Penelitian**

Berdasarkan Gambar 4 alur penelitian dijelaskan bahwa dalam melakukan penelitian dimulai dari input dataset. Setelah dataset dimasukkan maka tahap selanjutnya adalah dilakukan normalisasi pada dataset yang ada, selanjutnya dilakukan feature selection pada dataset. Setelah itu, dilakukan clusterisasi dengan menggunakan algoritma yaitu K-Means. Setelah dilakukan clusterisasi, dilakukan perhitungan prediksi dengan menggunakan BiLSTM dan GRU. Setelah didapatkan hasil, akan dilakukan evaluasi dengan menggunakan MSE dan R<sup>2</sup>. Setelah dilakukan evaluasi, akan didapatkan output yaitu prediksi dan evaluasi per cluster K-Means.

**HASIL DAN PEMBAHASAN**

Hasil pengujian menggunakan metode BiLSTM dan GRU dengan 100 epoch, dilakukan dengan alat analisis yang menggunakan bahasa pemrograman Python. Langkah awal dalam proses analisis dengan Python adalah mempersiapkan pustaka-pustaka yang diperlukan. Beberapa pustaka yang digunakan meliputi itertools, numpy, pandas, seaborn, matplotlib, serta labelencoder dan minmaxscaler dari sklearn.preprocessing. Cara memanggil pustaka-pustaka ini diilustrasikan dalam Gambar 4:

```
import itertools
import numpy as np
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.preprocessing import LabelEncoder
from sklearn.preprocessing import MinMaxScaler
from sklearn.cluster import KMeans
from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential, load_model
from tensorflow.keras.layers import Dropout, Dense, LSTM, Bidirectional
from keras.callbacks import EarlyStopping, ModelCheckpoint
from sklearn.metrics import r2_score

# Untuk menghitung MAPE
def mean_absolute_percentage_error(y_true, y_pred):
    return round(np.mean(np.abs((y_true - y_pred) / y_true)) * 100, 2)
```

**Gambar 4. Perintah Library Python**

Langkah selanjutnya adalah memeriksa dimensi dataset, yaitu jumlah baris dan kolom yang terdapat dalam dataset tersebut. Lalu melakukan pemeriksaan terhadap nilai yang kosong. Kemudian melakukan Mengubah data kategorikal menjadi representasi numerik. Adapun hasil dari pengubahan data kategorikal menjadi numerik, antara lain:


	Company	TypeName	Ram	Weight	Price	TouchScreen	Ips	Ppi	Cpu_brand	HDD	SSD	Gpu_brand	Os
0	1	4	8	1.37	11.175755	0	1	226.983005	2	0	128	1	0
1	1	4	8	1.34	10.776777	0	0	127.677940	2	0	0	1	0
2	7	3	8	1.86	10.329831	0	0	141.211998	2	0	256	1	1
3	1	4	16	1.83	11.814476	0	1	220.534624	3	0	512	0	0
4	1	4	8	1.37	11.473101	0	1	226.983005	2	0	256	1	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1268	2	3	4	2.20	10.556257	0	0	100.454670	3	500	0	2	2
1269	10	0	4	1.80	10.433899	1	1	157.350512	3	0	128	1	2
1270	10	0	16	1.30	11.288115	1	1	276.053530	3	0	512	1	2
1271	10	3	2	1.50	9.409283	0	0	111.935204	4	0	0	1	2
1272	7	3	6	2.19	10.614129	0	0	100.454670	3	1000	0	0	2

1273 rows x 13 columns

**Gambar 5. Hasil Pengubahan Data Kategorikal Menjadi Numerik**


Langkah berikutnya adalah melakukan visualisasi data dalam bentuk histogram untuk

memperoleh pemahaman tentang distribusi variabel numerik dalam dataset. Adapun hasil untuk melihat histogram, antara lain:



Gambar 6. Hasil Distribusi Price

Langkah berikutnya adalah melakukan seleksi fitur, di mana kita memilih subset fitur yang paling relevan atau signifikan dalam dataset untuk digunakan dalam analisis lebih lanjut. Adapun hasil untuk menghitung matriks, antara lain:



Gambar 7. Hasil Menghitung Matriks

Langkah selanjutnya adalah melakukan korelasi fitur terhadap target, di mana dilakukan evaluasi hubungan antara fitur-fitur dalam dataset dengan variabel target. Setelah itu, dilakukan penampilan korelasi antara fitur-fitur tersebut dan target. Adapun hasil untuk korelasi, antara lain:

```

Price          1.000000
Ram            0.680519
SSD           0.658808
Ppi           0.480687
Gpu_brand     0.363772
Ips           0.279240
Os            0.221188
Cpu_brand     0.201990
TouchScreen   0.194289
Weight        0.151386
Company       0.138395
HDD           -0.097361
TypeName      -0.125212
Name: Price, dtype: float64
    
```



Gambar 8. Hasil Dari Korelasi

Langkah selanjutnya adalah menetapkan threshold pada 0,1 untuk seleksi fitur. Fitur-fitur yang memiliki korelasi yang melebihi threshold tersebut akan dipilih. Setelah itu, hasilnya akan ditampilkan dengan mencetak fitur-fitur yang terpilih. Langkah selanjutnya adalah menyiapkan variabel independen (X) dan variabel dependen (y) untuk proses pemodelan. Variabel independen akan terdiri dari fitur-fitur yang telah dipilih, sedangkan variabel dependen akan menjadi target yang ingin diprediksi. Setelah menyiapkan variabel independen dan dependen, langkah berikutnya adalah melakukan normalisasi atribut (fitur-fitur) agar memiliki skala yang sebanding. Hal ini dapat dilakukan dengan menggunakan teknik normalisasi seperti Min-Max Scaling atau Z-score Scaling. Adapun hasil normalisasi, antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price
0	0.096774	0.125	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.175755
1	0.096774	0.000	0.141646	0.5	0.0	0.0	0.50	0.0	0.162095	0.055556	0.8	10.776777
2	0.096774	0.250	0.193326	0.5	0.0	0.5	0.50	0.0	0.291771	0.388889	0.6	10.329931
3	0.225806	0.500	0.496221	0.0	1.0	0.0	0.75	0.0	0.284289	0.055556	0.8	11.814476
4	0.096774	0.250	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.473101
...	...	...	...	...	...	...	...	...	...	...	...	...
1268	0.032258	0.000	0.037694	1.0	0.0	1.0	0.75	0.0	0.376559	0.111111	0.6	10.555257
1269	0.032258	0.125	0.254951	0.5	1.0	1.0	0.75	1.0	0.276808	0.555556	0.0	10.433899
1270	0.225806	0.500	0.708221	0.5	1.0	1.0	0.75	1.0	0.152120	0.555556	0.0	11.288115
1271	0.000000	0.000	0.081532	0.5	0.0	1.0	1.00	0.0	0.201995	0.555556	0.6	9.409283
1272	0.064516	0.000	0.037694	0.0	0.0	1.0	0.75	0.0	0.374065	0.388889	0.6	10.614129

1273 rows x 12 columns

Gambar 9. Hasil Normalisasi Data

Setelah melakukan normalisasi, langkah berikutnya adalah melakukan perhitungan menggunakan algoritma K-Means. Kita akan mulai dengan menentukan jumlah cluster yang diinginkan, dalam hal ini adalah 3 cluster. Adapun hasil dari menentukan cluster dan penambahan kolom dalam variabel 'cluster', antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price	clusters
0	0.096774	0.125	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.175755	1
1	0.096774	0.000	0.141646	0.5	0.0	0.0	0.50	0.0	0.162095	0.055556	0.8	10.776777	0
2	0.096774	0.250	0.193326	0.5	0.0	0.5	0.50	0.0	0.291771	0.388889	0.6	10.329931	0
3	0.225806	0.500	0.496221	0.0	1.0	0.0	0.75	0.0	0.284289	0.055556	0.8	11.814476	1
4	0.096774	0.250	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.473101	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1268	0.032258	0.000	0.037694	1.0	0.0	1.0	0.75	0.0	0.376559	0.111111	0.6	10.555257	0
1269	0.032258	0.125	0.254951	0.5	1.0	1.0	0.75	1.0	0.276808	0.555556	0.0	10.433899	1
1270	0.225806	0.500	0.708221	0.5	1.0	1.0	0.75	1.0	0.152120	0.555556	0.0	11.288115	1
1271	0.000000	0.000	0.081532	0.5	0.0	1.0	1.00	0.0	0.201995	0.555556	0.6	9.409283	0
1272	0.064516	0.000	0.037694	0.0	0.0	1.0	0.75	0.0	0.374065	0.388889	0.6	10.614129	0

1273 rows x 13 columns

Gambar 10. Hasil Penentuan Kluster

### Hasil Prediksi Harga Laptop Menggunakan BiLSTM

Langkah pertama adalah membuat DataFrame baru `data\_cluster1`, yang berisi baris-baris dari `data\_norm` di mana nilai dalam kolom 'clusters' adalah 0. Adapun hasil dari membuat dataframe data cluster1, antara lain:

Row	ESD	Psi	Cpu_brand	Isa	Os	Cpu_brand	TouchScreen	Weight	Company	PriceName	Price	clusters	
1	0.096774	0.00	0.141040	0.0	0.0	0.0	0.00	0.0	0.162056	0.000000	0.0	10.770777	0
2	0.096774	0.00	0.192228	0.0	0.0	0.0	0.00	0.0	0.204771	0.000000	0.0	10.320931	0
3	0.032258	0.00	0.037894	0.0	0.0	1.0	0.00	0.0	0.361821	0.000000	0.0	9.997929	0
10	0.032258	0.00	0.037894	0.0	0.0	0.5	0.00	0.0	0.291771	0.000000	0.0	9.951688	0
11	0.032258	0.00	0.192228	0.0	0.0	0.0	0.25	0.0	0.204771	0.000000	0.0	9.819070	0
1266	0.096774	0.00	0.037894	0.0	0.0	0.0	0.75	0.0	0.461490	0.222222	0.0	10.007932	0
1267	0.000000	0.00	0.109000	0.0	0.0	1.0	1.00	0.0	0.115701	0.300000	0.4	9.317088	0
1269	0.032258	0.00	0.037894	1.0	0.0	1.0	0.75	0.0	0.370000	0.101111	0.0	10.000297	0
1271	0.000000	0.00	0.001132	0.0	0.0	1.0	1.00	0.0	0.201960	0.000000	0.0	0.403263	0
1272	0.004010	0.00	0.037894	0.0	0.0	1.0	0.75	0.0	0.274000	0.000000	0.0	10.014120	0

400 rows x 13 columns


Gambar 11. Hasil Membuat DataFrame Data Cluster1

Langkah berikutnya melakukan pembagian data menjadi data train dan data testing dengan proporsi 80%:20%, setelah itu mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster1. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train1 data shape : (372, 1, 11)
X_test1 data shape : (94, 1, 11)
```

Gambar 12. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:



Gambar 13. Tampilan Model Loss

Langkah selanjutnya adalah menentukan data untuk cluster kedua setelah proses klusterisasi. Ini dilakukan dengan membuat DataFrame baru bernama `data\_cluster2`, yang berisi baris-baris dari `data\_norm` di mana nilai dalam kolom 'clusters' adalah 1. Adapun hasil dari membuat dataframe data cluster2, antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price	clusters
0	0.096774	0.125	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.175755	1
3	0.225806	0.500	0.496221	0.0	1.0	0.0	0.75	0.0	0.284289	0.055556	0.8	11.814476	1
4	0.096774	0.250	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.473101	1
6	0.225806	0.000	0.496221	0.5	1.0	0.0	0.75	0.0	0.336658	0.055556	0.8	11.644108	1
9	0.096774	0.250	0.254951	0.5	1.0	1.0	0.50	0.0	0.226933	0.000000	0.8	10.621952	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1255	0.225806	0.125	0.140339	1.0	1.0	1.0	0.75	0.0	0.825436	0.111111	0.2	11.525170	1
1260	0.096774	0.500	0.286575	0.5	1.0	1.0	1.00	0.0	0.127182	0.111111	0.8	10.567235	1
1264	0.096774	0.000	0.193326	1.0	1.0	1.0	0.75	0.0	0.476309	0.555556	0.6	10.776844	1
1269	0.032258	0.125	0.254951	0.5	1.0	1.0	0.75	1.0	0.276808	0.555556	0.0	10.433899	1
1270	0.225806	0.500	0.708221	0.5	1.0	1.0	0.75	1.0	0.152120	0.555556	0.0	11.288115	1

336 rows x 13 columns


Gambar 14. Hasil Membuat DataFrame Data Cluster2

Langkah berikutnya mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster2. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train2 data shape : (268, 1, 11)
X_test2 data shape : (68, 1, 11)
```

Gambar 15. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:




Gambar 16. Tampilan Model Loss

Langkah selanjutnya adalah membuat DataFrame data\_cluster3, yang hanya berisi baris-baris dari DataFrame data\_norm di mana nilai dalam kolom 'clusters' adalah 2. berikutnya mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster3. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train3 data shape : (376, 1, 11)
X_test3 data shape : (95, 1, 11)
```

Gambar 17. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:



Gambar 18. Tampilan Model Loss

Tahapan terakhir adalah melakukan evaluasi komparatif, yaitu proses membandingkan kinerja berbagai model yang telah dilatih dan diuji untuk menentukan model terbaik berdasarkan metrik kinerja yang telah ditentukan. Adapun hasil dari evaluasi komparatif, antara lain:

	Cluster	R2	MAPE(%)
0	Cluster 1	0.086	3.01
1	cluster 2	0.144	3.24
2	cluster 3	0.205	2.80

Gambar 19. Hasil Evaluasi Komparatif

### Hasil Prediksi Harga Laptop Menggunakan GRU

Langkah pertama adalah membuat DataFrame baru `data\_cluster1`, yang berisi baris-baris dari `data\_norm` di mana nilai dalam kolom 'clusters' adalah 0. Setelah itu, DataFrame `data\_cluster1` ditampilkan. Adapun hasil dari membuat dataframe data cluster1, antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price	clusters
1	0.096774	0.00	0.141646	0.5	0.0	0.0	0.50	0.0	0.162095	0.055556	0.8	10.776777	0
2	0.096774	0.25	0.193326	0.5	0.0	0.5	0.50	0.0	0.291771	0.388889	0.6	10.329931	0
5	0.032258	0.00	0.037694	0.0	0.0	1.0	0.00	0.0	0.351621	0.000000	0.6	9.967026	0
10	0.032258	0.00	0.037694	0.5	0.0	0.5	0.50	0.0	0.291771	0.388889	0.6	9.951658	0
11	0.032258	0.00	0.193326	0.5	0.0	0.5	0.25	0.0	0.291771	0.388889	0.6	9.819076	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1266	0.096774	0.00	0.037694	0.0	0.0	0.5	0.75	0.0	0.401496	0.222222	0.6	10.667632	0
1267	0.000000	0.00	0.169965	0.5	0.0	1.0	1.00	0.0	0.119701	0.388889	0.4	9.317895	0
1268	0.032258	0.00	0.037694	1.0	0.0	1.0	0.75	0.0	0.376569	0.111111	0.6	10.555257	0
1271	0.000000	0.00	0.081532	0.5	0.0	1.0	1.00	0.0	0.201995	0.555556	0.6	9.409283	0
1272	0.064516	0.00	0.037694	0.0	0.0	1.0	0.75	0.0	0.374065	0.388889	0.6	10.614129	0

466 rows x 13 columns


Gambar 20. Hasil Membuat DataFrame Data Cluster1

Langkah berikutnya mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster1. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train1 data shape : (372, 1, 11)
X_test1 data shape : (94, 1, 11)
```

Gambar 21. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:



Gambar 22. Tampilan Model Loss

Langkah selanjutnya adalah menentukan data untuk cluster kedua setelah proses klusterisasi. Ini dilakukan dengan membuat DataFrame baru bernama `data\_cluster2`, yang berisi baris-baris dari `data\_norm` di mana nilai dalam kolom 'clusters' adalah 1. Adapun hasil dari membuat dataframe data cluster2, antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price	clusters
0	0.096774	0.125	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.175755	1
3	0.225606	0.500	0.496221	0.0	1.0	0.0	0.75	0.0	0.284289	0.055556	0.8	11.814476	1
4	0.096774	0.250	0.520844	0.5	1.0	0.0	0.50	0.0	0.169576	0.055556	0.8	11.473101	1
6	0.225606	0.000	0.496221	0.5	1.0	0.0	0.75	0.0	0.336658	0.055556	0.8	11.644108	1
9	0.096774	0.250	0.254951	0.5	1.0	1.0	0.50	0.0	0.226933	0.000000	0.8	10.621952	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1255	0.225606	0.125	0.140339	1.0	1.0	1.0	0.75	0.0	0.825436	0.111111	0.2	11.525170	1
1260	0.096774	0.500	0.286575	0.5	1.0	1.0	1.00	0.0	0.127182	0.111111	0.8	10.567235	1
1264	0.096774	0.000	0.193326	1.0	1.0	1.0	0.75	0.0	0.476309	0.555556	0.6	10.770844	1
1269	0.032258	0.125	0.254951	0.5	1.0	1.0	0.75	1.0	0.276908	0.555556	0.0	10.433899	1
1270	0.225606	0.500	0.708221	0.5	1.0	1.0	0.75	1.0	0.152120	0.555556	0.0	11.288115	1

336 rows x 13 columns


Gambar 23. Hasil Membuat DataFrame Data Cluster2

Langkah berikutnya mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster2. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train2 data shape : (268, 1, 11)
X_test2 data shape : (68, 1, 11)
```

Gambar 24. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:



Gambar 25. Tampilan Model Loss

Langkah selanjutnya adalah membuat DataFrame data\_cluster3, yang hanya berisi baris-baris dari DataFrame data\_norm di mana nilai dalam kolom 'clusters' adalah 2. Adapun hasil dari membuat dataframe data cluster3, antara lain:

	Ram	SSD	Ppi	Gpu_brand	Ips	Os	Cpu_brand	TouchScreen	Weight	Company	TypeName	Price	clusters
7	0.096774	0.000	0.141646	0.5	0.0	0.0	0.50	0.0	0.162095	0.055556	0.8	11.030615	2
8	0.225806	0.500	0.254951	1.0	0.0	1.0	0.75	0.0	0.152120	0.111111	0.8	11.285443	2
23	0.096774	0.250	0.286575	0.5	0.0	1.0	0.50	1.0	0.231920	0.222222	0.0	10.683646	2
26	0.096774	0.000	0.141646	0.5	0.0	0.0	0.50	0.0	0.164589	0.055556	0.8	10.977717	2
28	0.096774	0.500	0.193326	0.5	0.0	1.0	0.75	0.0	0.296758	0.222222	0.8	11.144141	2
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1242	0.225806	0.500	0.140339	1.0	0.0	1.0	0.75	1.0	0.518703	0.222222	0.0	11.470547	2
1243	0.032258	0.250	0.254951	0.5	0.0	1.0	0.50	0.0	0.211970	0.388889	0.6	10.978617	2
1248	0.096774	0.250	0.708221	0.5	0.0	1.0	0.50	1.0	0.137157	0.222222	0.0	11.478299	2
1258	0.096774	0.125	0.193326	1.0	0.0	1.0	0.75	0.0	0.426434	0.611111	0.2	11.089517	2
1259	0.032258	0.125	0.254951	0.5	0.0	1.0	0.50	1.0	0.276808	0.555556	0.0	10.700607	2

471 rows x 13 columns

Gambar 26. Hasil Membuat DataFrame Data Cluster3


Langkah berikutnya mempersiapkan variabel independen (X1) dan dependen (y1) dari DataFrame data\_cluster3. Adapun hasil dari penentuan x dan y, antara lain:

```
X_train3 data shape : (376, 1, 11)
X_test3 data shape : (95, 1, 11)
```

Gambar 27. Hasil Dari Penentuan X dan Y

Selanjutnya, plot dari loss (kerugian) model selama proses pelatihan dan pengujian (validasi) dibuat. Adapun tampilan visualisasi plot, antara lain:





Gambar 28. Tampilan Model Loss

Tahapan terakhir adalah melakukan evaluasi komparatif, yaitu proses membandingkan kinerja berbagai model yang telah dilatih dan diuji untuk menentukan model terbaik berdasarkan metrik kinerja yang telah ditentukan. Adapun hasil dari evaluasi komparatif, antara lain:

	Cluster	R2	MAPE(%)
0	Cluster 1	-0.031	3.09
1	cluster 2	0.079	3.09
2	cluster 3	0.181	2.72

Gambar 29. Hasil Evaluasi Komparatif

### KESIMPULAN

Dari penelitian ini peneliti menggunakan 1273 data sampel, yang kemudian dilakukan fitur selection dengan menggunakan correlation matrix dan dilakukan normalisasi MinMaxScaler. Setelah itu hasil normalisasi tersebut dibagi menjadi data training 80% dan data testing 20%, dan kemudian dilakukan prediksi dengan menggunakan BiLSTM dan GRU. Berdasarkan evaluasi komparatif, model BiLSTM menunjukkan performa yang lebih baik dibandingkan GRU di sebagian besar cluster. Pada Cluster 3, BiLSTM memiliki nilai R2 tertinggi sebesar 0.205 dan MAPE terendah sebesar 2.80%, menunjukkan prediksi yang lebih akurat dibandingkan GRU dengan R2 sebesar 0.181 dan MAPE sebesar 2.72%. Untuk Cluster 1 dan Cluster 2, BiLSTM juga unggul dengan nilai R2 masing-masing sebesar 0.066 dan 0.144 serta MAPE sebesar 3.01% dan 3.24%, sementara GRU memiliki nilai R2 negatif (-0.031) di Cluster 1 dan 0.079 di Cluster 2 dengan MAPE sebesar 3.09% di kedua cluster. Secara keseluruhan, BiLSTM memberikan hasil prediksi yang lebih baik dibandingkan GRU.

Temuan ini memberikan implikasi praktis bagi perusahaan dalam mengoptimalkan penerapan WFH di masa depan. Perusahaan perlu melakukan investasi yang cukup pada infrastruktur TI, memberikan pelatihan dan pendampingan bagi karyawan, serta menyusun kebijakan dan panduan WFH yang jelas. Selain itu, diperlukan kolaborasi yang erat antara manajemen dan karyawan untuk menciptakan lingkungan kerja yang kondusif dan mendukung produktivitas dalam skema WFH.

**DAFTAR PUSTAKA**

- Afrianto, N., Fudholi, D., & Rani, S. (2021). Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik. *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)*.
- Carnegie, M., & Chairani. (2023). Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan. *Jurnal Media Informatika Budidarma*.
- Geekiyange, S. C., Tunkiel, A., & Sui, D. (2021). Drilling data quality improvement and information extraction with case studies. *Journal of Petroleum Exploration and Production Technology*, 819-837.
- Jose, J. (2022). Introduction To Time Series Analysis And Its Applications.
- Kafil, M. (2019). Penerapan Metode K-Nearest Neighbors Untuk Prediksi Penjualan Berbasis Web Pada Boutiq Dealove Bondowoso. *JATI (Jurnal Mahasiswa Teknik Informatika)*.
- Kristiana, L., & Miyanto, D. (2023). Penambahan Parameter PM2.5 dalam Prediksi Kualitas Udara : Long Short Term Memory. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 188-202.
- Lubis, M. (2021). Implementasi Artificial Intelligence pada system Manufaktur Terpadu. *Semnastek UISU*.
- Maharadja, A. N., Maulana, I., & Dermawa, B. A. (2021). Penerapan Metode Regresi Linear Berganda untuk Prediksi Kerugian Negara Berdasarkan Kasus Tindak Pidana Korupsi. *Journal of Applied Informatics and Computing (JAIC)*, 95-102.
- Manegopale, P., Nerpagar, K., Sawant, S., Shinde, M., & Chandarkar, K. (2023). Laptop Prediction & Comparison Using Machine Learning. *International Journal Of Innovative Research In Technology*, 174-179.
- Muhayat, T., Jayanta, & Chamidah, N. (2022). Prediksi harga Smartphone menggunakan Algoritma Multiple Linear Regression. *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*.
- Pan, S.-Y., Liao, Q., & Liang, Y.-T. (2022). Multivariable sales prediction for filling stations via GA improved BiLSTM. *Petroleum Science*, 2483-2496.
- Puteri, D. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *EULER: Jurnal Ilmiah Matematika, Sains dan Teknologi*, 35-43.
- Putra, A., & Juarna, A. (2021). Prediksi Produksi Daging Sapi Nasional dengan Metode Regresi Linier dan Regresi Polinomial. *Jurnal Ilmiah KOMPUTASI*.
- Salsabilla, R. (2023, Agustus 11). *Polusi Jakarta Makin Parah, Pemerintah Usul Karyawan WFH*. Diambil kembali dari CNBC INDONESIA: <https://www.cnbcindonesia.com/lifestyle/20230811130723-33-462204/polusi-jakarta-makin-parah-pemerintah-usul-karyawan-wfh>
- Sari, F. I., Gunawan, E. L., Adhigadany, C. A., & Lisanthoni, A. (2023). Model Prediksi Kepadatan Lalu Lintas: Perbandingan Antara Algoritma Random Forest dan XGBoost. *Seminar Nasional Sains Data 2023 (SENADA 2023)*, 296-303.
- Sartika, D., & Saluza, I. (2022). Penerapan Metode Principal Component Analysis (PCA) Pada Klasifikasi Status Kredit Nasabah Bank Sumsel Babel Cabang KM 12 Palembang Menggunakan Metode Decision Tree. *GENERIC Jurnal Ilmu Komputer dan Teknologi Informasi*, 14, 45-49.

- 
- Shi, S. (2023). Comparison of Real Estate Price Prediction Based on LSTM and LGBM. *Highlights in Science, Engineering and Technology*, 294-301.
- Siburian, A., Sitompul, D., & Sinurat, S. (2022). Laptop Price Prediction with Machine Learning Using Regression Algorithm. *JUSIKOM PRIMA (Jurnal Sistem Informasi dan Ilmu Komputer Prima)*.
- Ubaedi, I., & Djaksana, Y. M. (2022). Optimasi Algoritma C4.5 Menggunakan Metode Forward Selection Dan Stratified Sampling Untuk Prediksi Kelayakan Kredit. *JSiI | Jurnal Sistem Informasi*, 9, 17-26.
- Widjaja, W., Ashadi, M., & Cornellia, V. (2021). Budaya Kerja WFH di Masa Pandemi COVID-19 : Dampaknya Budaya Kerja WFH di Masa Pandemi COVID-19 : Dampaknya. *Jurnal Ecodemica: Jurnal Ekonomi, Manajemen, dan Bisnis*, 103-112.
- Yunizar, A., Rismawan, T., & Midyanti, D. (2023). Penerapan Metode Recurrent Neural Network Model Gated Recurrent Unit Untuk Prediksi Harga Cryptocurrency. *Coding : Jurnal Komputer dan Aplikasi* .



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/)