

# Forecasting the Exchange Rate of Yen to Rupiah Using the Long Short-Term Memory Method

Anggi Adrian Danis, Yenni Kurniawati\*, Nonong Amalita, Fadhilah Fitri

Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

\*Corresponding author: [yennikurniawati@fmipa.unp.ac.id](mailto:yennikurniawati@fmipa.unp.ac.id)

Submitted : 06 Oktober 2023

Revised : 25 Oktober 2023

Accepted : 14 November 2023

## ABSTRACT

*Long Short-Term Memory (LSTM) is a modification of the Recurrent Neural Network (RNN) to address the problems of exploding and vanishing gradients and make it possible to manage long-term information. To tackle these problems, modifications were made to the RNN by providing memory cells that can store information for long periods. This study aimed to forecast the exchange rate of Yen to Rupiah using the LSTM method. The data used in this research is daily purchasing rate data from January 2020 to May 2023, which consists of 848 observations. The data was divided into two sets: 80% for training and 20% for testing. For the forecasting process, experiments were conducted to identify the best model by adjusting several hyperparameters. The performance of each model was evaluated using the Mean Absolute Percentage Error (MAPE). According to the experimental results, the best model was the LSTM model with a batch size of 20, 150 epochs, and 50 neurons per layer, which yielded an MAPE value of 1,5399.*

**Keywords:** Exchange Rate, Hyperparameter, LSTM, MAPE



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

## I. PENDAHULUAN

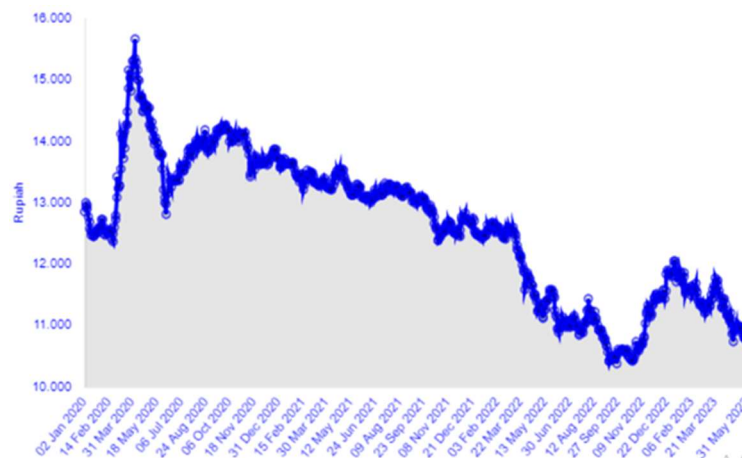
Sebagai salah satu pilar utama pertumbuhan ekonomi Indonesia, ekspor memainkan peran vital dalam mendukung stabilitas dan perkembangan ekonomi negara. Ekspor sangat penting bagi Indonesia karena berfungsi sebagai salah satu penyumbang cadangan devisa negara (Setyorani, 2018). Berdasarkan Badan Pusat Statistik (2023) Nilai ekspor Indonesia telah mengalami peningkatan dalam tiga tahun terakhir, dari 163,191 miliar dolar Amerika pada tahun 2020 menjadi 291,979 miliar dolar Amerika pada tahun 2022.

Salah satu negara tujuan ekspor Indonesia adalah Jepang. Indonesia dan Jepang memiliki perjanjian perdagangan bilateral yang dikenal dengan IJ-EPA (*Indonesia - Japan Economic Partnership Agreement*), yang telah berlaku sejak 1 Juli 2008. Manfaat dari perjanjian ini termasuk memperluas akses Indonesia ke pasar ekspor Jepang, khususnya untuk ekspor nonmigas seperti produk pertanian, perikanan, industri, dan produk kehutanan. Selain itu, perjanjian ini bertujuan untuk mempromosikan penyerapan tenaga kerja profesional Indonesia, meningkatkan investasi, dan menciptakan peluang kerjasama yang lebih luas antara kedua negara (Sekretariat Kabinet Republik Indonesia, 2023).

Bank Indonesia dan Kementerian Keuangan Jepang telah menyepakati untuk memperkuat kerangka kerja kerjasama penyelesaian dalam Mata Uang Lokal atau yang disebut LCS (*Local Currency Settlement*) antara kedua negara menggunakan mata uang rupiah Indonesia dan yen Jepang (Bank Indonesia, 2021). LCS merujuk pada penyelesaian bilateral transaksi antara dua negara yang dilakukan dalam mata uang masing-masing negara di mana penyelesaian transaksi dilakukan di yurisdiksi masing-masing negara. Inisiatif ini bertujuan untuk mengurangi ketergantungan pada dolar Amerika dalam transaksi perdagangan bilateral dan mendorong penggunaan mata uang lokal yang lebih luas (Bank Indonesia, 2020).

Semenjak Covid-19 terjadi, dari akhir tahun 2020 nilai yen terlihat mengalami penurunan. Nilai tukar yang tidak stabil ini akan memengaruhi ekspor Indonesia, sehingga memerlukan peramalan. Peramalan diperlukan karena jika nilai rupiah menjadi lebih kuat, dampaknya akan berupa penurunan ekspor Indonesia, yang berarti produk ekspor Indonesia akan menjadi lebih mahal bagi negara mitra perdagangan. Jika produk ekspor Indonesia menjadi

lebih mahal, maka ekspor Indonesia akan kurang kompetitif di pasar internasional (Ginting, 2013). Nilai tukar yen ke rupiah yang mengalami penurunan dapat dilihat pada Gambar 1.



(Sumber: Bank Indonesia)

**Gambar 1.** Grafik nilai tukar yen ke rupiah dari Januari 2020 – Mei 2023

Pada Gambar 1 terlihat bahwa pergerakan nilai tukar yen ke rupiah tidak stabil, hal ini bisa terlihat dari bulan Oktober 2020 nilai tukar yen ke rupiah cenderung memiliki tren turun hingga pada bulan November 2022. Dari bulan Januari 2020 sampai Oktober 2020 terlihat nilai tukar yen mengalami kenaikan dan penurunan, dan hal itu kembali terjadi pada bulan November 2022 sampai Mei 2023. Nilai tukar yen yang tidak stabil ini tentu tidak baik untuk ekspor Indonesia seperti yang dijelaskan sebelumnya. Dalam rangka menjaga stabilitas harga rupiah, yang sangat penting guna meningkatkan ekspor Indonesia, diperlukan peramalan nilai tukar rupiah agar kebijakan yang tepat dapat diambil untuk masa depan.

Peramalan menurut Hyndman dan Athanasopoulos (2018) adalah proses memprediksi masa depan berdasarkan informasi masa lalu dan saat ini. Ini adalah bagian penting dari proses perencanaan dan pengambilan keputusan dalam berbagai bidang, seperti bisnis, ekonomi, dan keuangan. Ada banyak metode yang dapat digunakan untuk meramalkan nilai tukar, yang merupakan data deret waktu, dan salah satu metode yang dapat digunakan untuk meramalkan data deret waktu adalah *Long Short-Term Memory* (LSTM).

Pada penelitian sebelumnya yang dilakukan Phoksawa dkk (2023) menggunakan LSTM dalam peramalan harga lembaran karet asap. Dalam proses LSTM memerlukan penyetyelan *hyperparameter* (*hyperparameter tuning*), dalam penelitian ini menggunakan beberapa *hyperparameter* yang bertujuan menemukan nilai *hyperparameter* optimal. Penelitian ini memperoleh model dengan *hyperparameter* optimal berupa 3 *layer* dengan jumlah *neuron* tiap *layer* 100, 150, 200 dan *epoch* 30, penelitian ini menghasilkan RMSE sebesar 2,412, MAPE sebesar 0,0413, dan tingkat akurasi 95,88%.

Penelitian ini menggunakan data nilai tukar rupiah dari Januari 2020 – Mei 2023 yang diambil dari Bank Indonesia. Berdasarkan uraian yang telah dipaparkan, tujuan penelitian ini adalah untuk meramalkan nilai tukar yen ke rupiah menggunakan LSTM dengan beberapa *hyperparameter*.

## II. METODE PENELITIAN

### A. Jenis Penelitian dan Sumber Data

Penelitian yang dilakukan adalah penelitian terapan, dalam penelitian ini menerapkan metode LSTM untuk melakukan peramalan pada nilai tukar yen pada rupiah. Penelitian ini menggunakan data sekunder yang diambil dari Bank Indonesia. Data yang digunakan adalah data nilai tukar yen ke rupiah dari Januari 2020 – Mei 2023

### B. Teknik Analisis Data

Analisis data dalam penelitian ini menggunakan bahasa pemrograman *Python* dengan *keras package* pada *Google Colab*. Adapun langkah-langkah dari masing-masing tahap dijelaskan sebagai berikut.

1. Melakukan normalisasi data nilai tukar yen ke rupiah.

Normalisasi bertujuan mengubah skala data menjadi kecil tanpa mengubah informasi data asli. Teknik normalisasi yang digunakan adalah *min-max scaling*, yang mengubah data menjadi skala [0,1] (Aldi dkk, 2018). Rumus *min-max scaling* adalah

$$x'_t = \frac{(x_t - \min_x)}{(\max_x - \min_x)} \quad (1)$$

Keterangan:

- $x'_t$  : data ke- $t$  setelah dinormalisasi
- $x_t$  : data asli ke- $t$  yang akan dinormalisasi
- $\min_x$ : nilai terendah data asli
- $\max_x$ : nilai tertinggi data asli

2. Membagi data


Data yang sudah dinormalisasi dibagi menjadi dua bagian, yaitu data latih dan data uji. Komposisi data latih sebanyak 80% dan data uji sebanyak 20%. Data latih digunakan untuk melatih model LSTM dan data uji digunakan untuk menguji model LSTM yang sudah dilatih.

3. Menentukan *Hyperparameter*

Metode LSTM memerlukan penyetelan *hyperparameter* (*hyperparameter tuning*), yang bertujuan untuk menemukan nilai *hyperparameter* optimal. Dalam penelitian ini ada beberapa *hyperparameter* yang digunakan untuk menemukan nilai *hyperparameter* optimal. Beberapa *hyperparameter* yang digunakan adalah *time step*, *learning rate*, *batch size*, *epoch*, *layer*, *neuron* tiap *layer*.

4. Pembentukan Model LSTM

LSTM adalah sebuah modifikasi dari RNN (*Recurrent neural network*) yang dirancang untuk mengatasi masalah *gradient* yang mengecil atau membesar, serta memungkinkan pengelolaan informasi jangka panjang. Untuk mencapai ini, dilakukan modifikasi pada arsitektur RNN dengan memberi sel memori yang dapat menyimpan informasi untuk periode yang lebih lama. LSTM menggabungkan beberapa *gate* yang berfungsi untuk mengendalikan aliran informasi dan mengatasi masalah *gradient* yang mengecil atau membesar (Manaswi, 2018). Arsitektur LSTM dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur LSTM ( Goyal dkk, 2018).

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (3)$$

$$\hat{C}_t = \tanh(W_{\hat{C}} \cdot x_t + U_{\hat{C}} \cdot h_{t-1} + b_{\hat{C}}) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \quad (5)$$

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

Keterangan :

- $f_t$  : *forget gate* ke  $t$
- $i_t$  : *input gate* ke  $t$
- $\hat{C}_t$  : vektor kandidat ke  $t$
- $C_t$  : *cell state* ke  $t$
- $o_t$  : *output gate* ke  $t$
- $h_t$  : hasil akhir ke  $t$

$\sigma$  : nilai dari fungsi *sigmoid*  
 $W$  : bobot *input* pada setiap *gate*  
 $x_t$  : nilai *input* pada waktu ke  $t$   
 $U$  : bobot hasil akhir sebelumnya pada setiap *gate*  
 $h_{t-1}$  : hasil akhir sebelumnya  
 $b$  : vektor *bias* pada setiap *gate*  
 $\tanh$  : nilai dari fungsi *tanh*

*Backpropagation* adalah sebuah teknik yang digunakan dalam pembelajaran jaringan saraf tiruan untuk menghitung *gradient* dari fungsi kesalahan terhadap bobot di setiap lapisan jaringan. Ini memungkinkan penyesuaian bobot secara iteratif selama proses pelatihan, sehingga jaringan saraf dapat belajar dari data yang diberikan. Berikut adalah langkah-langkah prosedur pelatihan (Zaccone dkk, 2017).

- a) Inisialisasi bobot secara acak.
- b) Untuk pelatihan.

*Forward pass* : menghitung kesalahan yang dilakukan model, dimulai dari Persamaan 2 sampai Persamaan 7 dan menghasilkan perbedaan keluaran yang dihasilkan dan keluaran yang diharapkan.

*Backward pass* : menghitung mundur kesalahan dimulai dari Persamaan 7 sampai Persamaan 2.

- c) Menyesuaikan bobot untuk meminimalkan fungsi kesalahan dengan optimasi.

5. Kemudian dilanjutkan dengan optimasi fungsi kesalahan dengan algoritma SGD (*Stochastic Gradient Descent*) SGD adalah algoritma umum yang digunakan dalam *machine learning* dan *deep learning* untuk melatih model, terutama dalam konteks tugas-tugas pembelajaran mesin. Tujuan penggunaan SGD adalah untuk meminimalkan fungsi kesalahan dengan memperbarui bobot berdasarkan *gradient* dan *learning rate* (Zocca dkk, 2017).

$$W_b = W_l - \lambda * \delta W \quad (8)$$

Keterangan:

$W_b$  : bobot baru  
 $W_l$  : bobot lama  
 $\lambda$  : *learning rate*  
 $\delta$  : *gradient*

#### 6. Validasi Model

Validasi model adalah langkah penting dalam melakukan peramalan. Tujuan dari validasi model adalah untuk melihat model yang dihasilkan sudah baik atau tidak. Baik atau tidaknya model bisa dihitung melalui ukuran kesalahan pada model. Pada penelitian ini akan dilakukan validasi model menggunakan *Mean Absolute Percentage Error* (MAPE). Menurut Chen dkk (2018) Model peramalan terbaik dapat dilihat dari nilai MAPE yang terkecil.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (9)$$

Keterangan :

$y_t$  : Nilai pengamatan pada waktu ke- $t$   
 $\hat{y}_t$  : Nilai prediksi pada waktu ke- $t$   
 $n$  : Banyak amatan

7. Pemilihan model terbaik dengan evaluasi model, model terbaik adalah model yang memiliki nilai MAPE terkecil.
8. Ulangi Langkah 4 – 7 untuk semua model.
9. Model terbaik dari tahap pelatihan digunakan untuk melakukan pengujian dari data uji menggunakan *forward pass* dengan Persamaan 1 sampai Persamaan 6.
10. Melakukan peramalan kurs yen terhadap rupiah menggunakan model terbaik.
11. Denormalisasi hasil peramalan

Denormalisasi adalah pengembalian data dari normalisasi ke data asli, denormalisasi dilakukan setelah data hasil prediksi didapatkan, data akan di ubah kembali ke bentuk aslinya dengan rumus sebagai berikut (Lattifiaa dkk, 2022).

$$x = y(x_{max} - x_{min}) + x_{min} \quad (10)$$

Keterangan :

$y_t$  : Nilai pengamatan pada waktu ke- $t$   
 $\hat{y}_t$  : Nilai prediksi pada waktu ke- $t$   
 $n$  : Banyak amatan

### III. HASIL DAN PEMBAHASAN


Pada penelitian ini akan dilakukan peramalan nilai tukar yen ke rupiah dengan metode LSTM. Dalam proses LSTM memerlukan penyetelan *hyperparameter* (*hyperparameter tuning*) yang bertujuan untuk menemukan nilai *hyperparameter* optimal yang akan digunakan untuk peramalan. Pada penelitian ini ada 3 *hyperparameter* yang nilainya ditetapkan yaitu time step (2), learning rate (0,001), layer yang berjumlah 4, dan 3 *hyperparameter* yang nilainya diatur, yaitu *batch size* (20, 40, 60), *epoch* (50, 100, 150), dan *neuron* tiap *layer* (50, 100, 150) dari *hyperparameter* ini akan menghasilkan kombinasi model yang berjumlah 27 model. Dari 27 model ini akan dipilih model terbaik berdasarkan nilai MAPE terkecil untuk melakukan peramalan. Nilai MAPE semua model dapat dilihat pada Tabel 1.

**Tabel 1.** Hasil pelatihan untuk pembentukan model

| Nomor | Model ( <i>batch size</i> ,<br><i>epoch</i> , <i>neuron</i> tiap<br><i>layer</i> ) | MAPE          | Nomor | Model ( <i>batch size</i> ,<br><i>epoch</i> , <i>neuron</i> tiap<br><i>layer</i> ) | MAPE   |
|-------|--|---------------|-------|--|--------|
| 1     | 20, 50, 50   | 1,6736        | 15    | 40, 100, 150   | 5,6210 |
| 2     | 20, 50, 100  | 2,1098        | 16    | 40, 150, 50  | 1,6162 |
| 3     | 20, 50, 150  | 7,9209        | 17    | 40, 150, 100   | 2,1532 |
| 4     | 20, 100, 50  | 1,5768        | 18    | 40, 150, 150   | 5,2403 |
| 5     | 20, 100, 100   | 1,9551        | 19    | 60, 50, 50   | 1,8444 |
| 6     | 20, 100, 150   | 7,0856        | 20    | 60, 50, 100  | 2,3477 |
| 7     | <b>20, 150, 50</b>   | <b>1,5399</b> | 21    | 60, 50, 150  | 5,5390 |
| 8     | 20, 150, 100   | 1,8265        | 22    | 60, 100, 50  | 1,7864 |
| 9     | 20, 150, 150   | 6,3847        | 23    | 60, 100, 100   | 2,2653 |
| 10    | 40, 50, 50   | 1,7815        | 24    | 60, 100, 150   | 5,2524 |
| 11    | 40, 50, 100  | 2,3245        | 25    | 60, 150, 50  | 1,7305 |
| 12    | 40, 50, 150  | 6,0546        | 26    | 60, 150, 100   | 2,1943 |
| 13    | 40, 100, 50  | 1,6788        | 27    | 60, 150, 150   | 4,9963 |
| 14    | 40, 100, 100   | 2,2345        |       |  |        |

Berdasarkan hasil pelatihan untuk mencari model peramalan terbaik untuk nilai tukar yen ke rupiah menggunakan metode LSTM, Tabel 1 menunjukkan bahwa nilai MAPE terkecil diperoleh pada model ke tujuh, yang memiliki nilai sebesar 1,5399. Model ini memiliki *batch size* 20, *epoch* 150, dan 50 *neuron* untuk setiap *layer*. Model ini akan digunakan pada proses pengujian, grafik dari model ini selama proses pengujian dapat dilihat pada Gambar 3.

Berdasarkan Tabel 1 terlihat peningkatan jumlah *neuron* tiap *layer* mempengaruhi nilai MAPE. Semakin tinggi jumlah *neuron* tiap *layer* semakin tinggi nilai MAPE yang dihasilkan model. Sementara itu terlihat juga peningkatan jumlah *epoch* membuat MAPE yang dihasilkan menjadi lebih kecil. Namun peningkatan jumlah *batch size* tidak selalu mempengaruhi besar atau kecilnya MAPE yang dihasilkan model.



**Gambar 3.** Grafik model terbaik selama proses pengujian untuk peramalan nilai tukar yen ke rupiah.

Berdasarkan Gambar 3 terlihat grafik dari pengujian yang berwarna oranye pada awalnya tidak mendekati grafik nilai aktual yang berwarna biru, namun mendekati pertengahan grafik pengujian yang berwarna oranye perlahan mendekati grafik nilai aktual yang berwarna biru dan mengikuti pola grafik nilai aktual. Berdasarkan hal tersebut terlihat model terbaik yang didapatkan dari pelatihan sudah sangat baik untuk melakukan peramalan pada data yang belum pernah digunakan, hal ini dibuktikan dengan nilai MAPE pada pengujian yang kecil yaitu 1,9711.

**Tabel 2.** Hasil peramalan untuk 10 periode kedepan.

| Periode | Hasil Peramalan | Periode | Hasil Peramalan |
|---------|-----------------|---------|-----------------|
| 1       | 112,24          | 6       | 114,39          |
| 2       | 112,76          | 7       | 114,56          |
| 3       | 113,48          | 8       | 114,68          |
| 4       | 113,85          | 9       | 114,77          |
| 5       | 114,17          | 10      | 114,83          |

Berdasarkan Tabel 2 untuk peramalan nilai tukar yen 10 periode kedepan terlihat mengalami kenaikan yang tidak terlalu jauh. Berdasarkan peramalan 10 periode kedepan juga terlihat adanya tren untuk nilai tukar yen ke rupiah.

#### IV. KESIMPULAN

Penelitian ini bertujuan untuk meramalkan nilai tukar yen ke rupiah menggunakan metode LSTM. Data yang digunakan adalah kurs beli harian yen ke rupiah dari Januari 2020 hingga Mei 2023. Untuk menemukan model terbaik dalam meramalkan nilai tukar yen ke rupiah menggunakan metode LSTM, berbagai model diuji. Model terbaik yang diperoleh adalah model LSTM dengan *timestep* 2, *learning rate* 0,001, *batch size* 20, *epoch* 150, dengan 4 *layer* LSTM dengan masing-masing *layer* memiliki 50 *neuron*, yang menghasilkan MAPE sebesar 1,5399. Nilai MAPE 1,5399 menunjukkan kemampuan peramalan yang sangat baik. Dengan menggunakan model yang diperoleh, dilakukan peramalan untuk 10 periode berikutnya, seperti yang ditunjukkan dalam Tabel 2. Pada penelitian ini hanya melakukan uji coba untuk beberapa *hyperparameter* dan dengan optimisasi SGD. Untuk penelitian selanjutnya bisa dicoba dengan *hyperparameter* yang lain dan dengan optimisasi yang lain. Dan untuk penelitian selanjutnya bisa dicoba dengan data lebih dari 5 tahun.

#### DAFTAR PUSTAKA

Aldi, M. W., Jondri, & Aditsania, A. (2018). Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *e-Proceeding of Engineering*, 5(2), 3548-3555.

- Badan Pusat Statistik. (2023). Diambil kembali dari <https://www.bps.go.id/subject/8/ekspor-impor.html#subjekViewTab5>
- Bank Indonesia. (2020). Diambil kembali dari <https://bicara131.bi.go.id/knowledgebase/article/KA-01093/en-us>
- Bank Indonesia. (2021). Diambil kembali dari [https://www.bi.go.id/id/publikasi/ruang-media/news-release/Pages/sp\\_2319121.aspx](https://www.bi.go.id/id/publikasi/ruang-media/news-release/Pages/sp_2319121.aspx)
- Chen, J. F., Do, Q. H., Nguyen, T. V., & Doan, T. T. (2018). Forecasting monthly electricity demands by wavelet neuro-fuzzy system optimized by heuristic algorithms. *Information*, 9(3).
- Ginting, A. M. (2013). Pengaruh Nilai Tukar Terhadap Ekspor Indonesia. *Buletin Ilmiah Litbang Perdagangan*, 7(1), 1-18.
- Goyal, P., Pandey, S., & Jain, K. (2018). *Deep Learning for Natural Language Processing: Creating Neural Networks with Python*. Apress.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Lattifiaa, T., Buanaa, P. W., & Rusjyanthib, N. K. (2022). Model Prediksi Cuaca Menggunakan Metode LSTM. *JITTER- Jurnal Ilmiah Teknologi dan Komputer*, 3(1).
- Manaswi, N. K. (2018). *Deep Learning with Applications Using Python*. Bangalore, Karnataka, India: Apress.
- Phoksawat, K., Phoksawat, E., & Chanakot, B. (2023). Forecasting smoked rubber sheets price based on a deep learning model with long short-term memory. *International Journal of Electrical and Computer Engineering (IJECE)*, 13, 688-696.
- Sekretariat Kabinet Republik Indonesia. (2023). Diambil kembali dari <https://setkab.go.id/perkembangan-perjanjian-perdagangan-bilateral-antara-indonesia-dengan-negara-mitra/>
- Setyorani, B. (2018). Pengaruh Nilai Tukar terhadap Ekspor dan Jumlah Uang Beredar di Indonesia. *Forum Ekonomi*, 20(1), 1-11.
- Zaccone, G., Karim, M. R., & Menshawy, A. (2017). *Deep Learning with TensorFlow*. Packt Publishing.
- Zocca, V., Spacagna, G., Slater, D., & Roelants, P. (2017). *Python Deep Learning*. Packt Publishing.