

PREDIKSI HARGA INDEKS *DOLLAR* PADA TAHUN 2019-2024 MENGUNAKAN *BACKPROPAGATION* JARINGAN SARAF TIRUAN

Nugroho Adi Putro*¹, Andhika Bayu W W², Calvin Collins Tan³,
Rajnaparamitha Kusumastuti⁴

¹²³⁴STMIK Amikom Surakarta

¹²³⁴Sukoharjo, Indonesia

Email: ¹putronugroho336@gmail.com, ²andikabayu058@gmail.com,
³calvinctkz@gmail.com, ⁴rajna@dosen.amikomsolo.ac.id

Abstract

This study aims to predict the United States Dollar Index (USD_X) using an Artificial Neural Network (ANN) model with a Backpropagation approach. Historical USD_X data from 2019 to 2021 was used to train the model, and predictions were made for USD_X values in 2024. The ANN model, consisting of two layers with 50 neurons in the hidden layer, was trained over 200 epochs. The prediction results indicate that the model can estimate USD_X values with a relatively low Mean Squared Error (MSE) and an acceptable percentage error based on the actual average value for 2024. The visualized results demonstrate that the ANN model can follow historical data patterns well, although there is room for improvement, particularly in capturing seasonal variations.

Keywords: Artificial Neural Network, Backpropagation, Mean Squared Error, Prediction, U.S. Dollar Index

Abstraksi

Penelitian ini bertujuan untuk memprediksi nilai Indeks Dollar Amerika Serikat (USD_X) menggunakan model Jaringan Syaraf Tiruan (JST) dengan pendekatan Backpropagation. Data historis USD_X dari tahun 2019 hingga 2021 digunakan sebagai data pelatihan model, dan prediksi dibuat untuk nilai USD_X tahun 2024. Model JST yang digunakan terdiri dari dua lapisan utama dengan 50 neuron pada lapisan tersembunyi, yang dilatih selama 200 epoch. Hasil prediksi menunjukkan bahwa model dapat mengestimasi nilai USD_X dengan Mean Squared Error (MSE) yang relatif rendah, dan persentase error yang dihitung berdasarkan rata-rata nilai aktual tahun 2024 berada dalam kisaran yang dapat diterima. Visualisasi hasil menunjukkan bahwa model JST mampu mengikuti pola data historis dengan baik, namun masih ada ruang untuk perbaikan, khususnya dalam menangani variasi musiman yang tidak terdeteksi dengan baik oleh model.

Kata Kunci: Backpropagation, Indeks Dollar AS, Jaringan Syaraf Tiruan, Mean Squared Error, Prediksi

1. PENDAHULUAN

Indeks Dollar Amerika Serikat (USDX) merupakan indikator ekonomi yang sangat penting dalam mengukur nilai tukar *Dollar AS* terhadap sekeranjang mata uang utama dunia. Indeks ini digunakan secara luas dalam berbagai keputusan ekonomi, baik dalam konteks perdagangan internasional, investasi, maupun kebijakan moneter[1]. Dengan demikian, kemampuan untuk memprediksi pergerakan nilai USDX dengan akurasi tinggi sangatlah berharga, terutama bagi pelaku pasar keuangan dan pembuat kebijakan[2].

Perkembangan teknologi komputasi dan teknik pembelajaran mesin dalam beberapa tahun terakhir telah membuka peluang baru untuk meningkatkan akurasi prediksi dalam bidang keuangan[3]. Salah satu teknik yang semakin mendapatkan perhatian adalah Jaringan Syaraf Tiruan (JST). JST, terutama dengan algoritma *Backpropagation*, telah terbukti efektif dalam memodelkan hubungan non-linear yang kompleks dalam data, termasuk dalam analisis data keuangan[4].

Penelitian ini bertujuan untuk mengaplikasikan model JST dalam memprediksi nilai USDX. Dengan menggunakan data historis USDX dari tahun 2019 hingga 2021, penelitian ini akan mengembangkan model prediksi untuk tahun 2024. Model yang digunakan adalah model *Multi-Layer Perceptron* (MLP) dengan dua lapisan utama dan 50 neuron pada lapisan tersembunyi[5]. Proses pelatihan dilakukan selama 200 epoch untuk memastikan bahwa model dapat menangkap pola-pola penting dalam data historis tersebut[6].

Motivasi utama dari penelitian ini adalah manfaat potensial dari prediksi USDX yang akurat di berbagai sektor. Prediksi yang tepat dapat membantu mengurangi risiko keuangan, meningkatkan efisiensi dalam keputusan investasi, dan memberikan informasi yang lebih baik bagi pengambil kebijakan ekonomi[7]. Meskipun sudah ada berbagai model dan metode yang digunakan untuk prediksi USDX, masih ada kebutuhan untuk model prediktif yang lebih baik dan adaptif terhadap perubahan dinamis di pasar keuangan[8].

Dalam konteks ini, penelitian ini tidak hanya mengevaluasi efektivitas model JST dalam memprediksi USDX, tetapi juga mengidentifikasi area di mana perbaikan lebih lanjut dapat dilakukan[9]. Hal ini termasuk penanganan variasi musiman dan kejutan ekonomi eksternal yang mungkin tidak terdeteksi dengan baik oleh model yang ada. Hasil dari penelitian ini diharapkan dapat berkontribusi pada pengembangan alat prediksi keuangan yang lebih canggih di masa mendatang[10].

2. TINJAUAN PUSTAKA

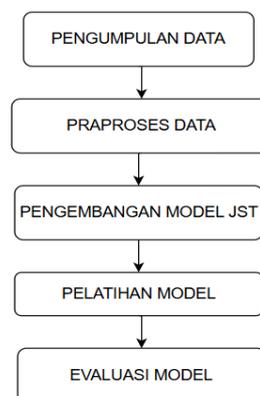
Pada penelitian sebelumnya banyak yang membahas tentang Jaringan Syaraf Tiruan (JST) dengan metode *backpropagation*. Salah yang berjudul “Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan *Backpropagation*” menunjukkan bahwa karena karakteristik prediksi data yang kompleks, algoritma ini terbukti efektif[11]. Dan mengindikasikan bahwa penggunaan JST memperoleh hasil peramalan yang baik pada jenis konteks yang berbeda seperti konsumsi air, nilai tukar

maupun beban listrik. Hasil yang didapatkan dalam penelitian ini antara lain dengan adanya syaratparameter iterasi maupun laju pembelajaran yang tepat model dapat mencapai tingkat kesalahan 0.0162 yang menunjukkan nilai rendah yang berarti memiliki tingkat akurasi yang tinggi dalam meramalkan permintaan koran.

Penelitian dengan judul “Prediksi Nilai Tukar Petani Menggunakan Jaringan Syaraf Tiruan *Backpropagation*” juga menekankan pentingnya pemodelan Nilai Tukar Petani sebagai indikator kesejahteraan nasional dari petani di Indonesia[12]. Mereka dalam penelitian mereka menggunakan data historis dan menerapkan metode *Backpropagation* untuk memprediksi Nilai Tukar Petani satu bulan ke depan. Implementasi menunjukkan bahwa orientasi node lapisan tersembunyi dan laju pembelajaran yang sesuai akan mencapai persentase akurasi 99,39% dengan persentase kesalahan rata-rata tidak lebih dari 0,61%. Inilah sebabnya mengapa *Artificial Neural Networks* dapat dianggap sebagai alat yang relevan dalam ekonomi prediktif dan, khususnya, di sektor pertanian.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan Jaringan Syaraf Tiruan (JST) untuk memprediksi nilai Indeks *Dollar* Amerika Serikat (USD_X) berdasarkan data historis. Metode penelitian ini dapat dibagi menjadi beberapa tahapan utama: pengumpulan data, praproses data, pengembangan model JST, pelatihan model, dan evaluasi model seperti pada Gambar 1.



Gambar 1. Kerangka Penelitian

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data historis USD_X dari tahun 2019 hingga 2021. Data ini diperoleh dari sumber terpercaya yang menyediakan informasi nilai USD_X secara harian. Data tersebut mencakup nilai pembukaan, penutupan, tertinggi, dan terendah setiap hari, serta volume perdagangan.

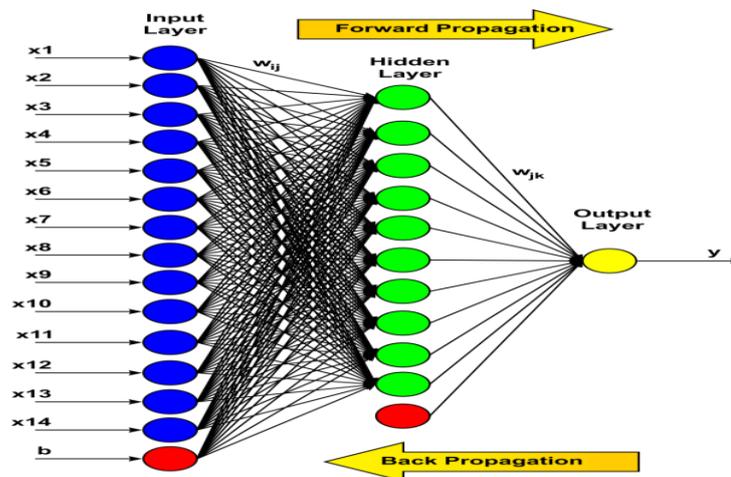
2. Praproses Data

Langkah pertama dalam praproses data adalah membersihkan dan mempersiapkan data untuk digunakan dalam model. Ini meliputi pengisian nilai yang hilang, normalisasi data untuk skala yang seragam, dan pembagian data menjadi data latih dan data uji.

Normalisasi dilakukan untuk memastikan bahwa semua fitur berada dalam rentang nilai yang sama, sehingga mempercepat konvergensi selama pelatihan model.

3. Pengembangan Model JST

Model yang dikembangkan dalam penelitian ini adalah model *Multi-Layer Perceptron* (MLP) dengan dua lapisan tersembunyi. Lapisan pertama terdiri dari 50 neuron dengan fungsi aktivasi ReLU (*Rectified Linear Unit*), sedangkan lapisan kedua menggunakan jumlah neuron yang sama dengan fungsi aktivasi yang sama. Lapisan keluaran menggunakan satu neuron dengan fungsi aktivasi linear untuk menghasilkan prediksi nilai USDX pada Gambar 2.



(Sumber: [Arsitektur Jaringan Syaraf Tiruan](#))

Gambar 2. Arsitektur ANN

4. Pelatihan Model

Pelatihan model dilakukan menggunakan algoritma *Backpropagation* dengan optimasi Adam (*Adaptive Moment Estimation*). Optimasi Adam menggabungkan keunggulan dari RMSProp (pengaturan pembelajaran adaptif berdasarkan varians gradien) dan Momentum (mempercepat konvergensi dengan memanfaatkan momentum gradien). Ini membuat Adam mampu bekerja lebih baik pada berbagai jenis dataset, baik yang jarang maupun padat. Model yang dilatih selama 100 epoch dengan batch size sebesar 32. Selama pelatihan, model belajar meminimalkan *loss function* yang diukur menggunakan *Mean Squared Error* (MSE). Data dibagi menjadi 80% untuk data latih dan 20% untuk data uji, dengan evaluasi dilakukan pada setiap epoch untuk memantau kinerja model.

a. Optimisasi dengan Adam

Optimisasi Adam mengkombinasikan keunggulan dari dua metode optimasi yaitu RMSProp dan Momentum. Rumus pembaruan bobot pada Adam pada rumus (1) adalah [13]:

$$\begin{aligned} m_t &= \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \\ v_t &= \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \end{aligned}$$

$$\begin{aligned}\widehat{mt} &= \frac{mt}{1 - \beta_1^t} \\ \widehat{vt} &= \frac{mt}{1 - \beta_2^t} \\ \theta t &= \theta_{t-1} - \frac{\alpha \widehat{mt}}{\sqrt{\widehat{vt} + \epsilon}}\end{aligned}\quad (1)$$

Keterangan : gt adalah gradien pada waktu t , mt adalah estimasi rata-rata momentum, vt adalah estimasi momentum gradien kuadrat, θt adalah parameter model (misalnya bobot), α adalah learning rate, ϵ adalah konstanta kecil untuk mencegah pembagian dengan nol, β_1 dan β_2 adalah faktor eksponensial untuk rata-rata momentum.

b. Loss Function (*Mean Squared Error*)

Untuk mengukur seberapa baik model memprediksi, *loss function Mean Squared Error* (MSE) digunakan rumus (2) [14]:

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n}\quad (2)$$

Keterangan: y_i adalah nilai asli, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah data.

5. Evaluasi Model

Setelah pelatihan selesai, model dievaluasi berdasarkan kemampuan memprediksi nilai USDX untuk tahun 2024. Metrik yang digunakan untuk evaluasi adalah *Mean Squared Error* (MSE) dan persentase error dibandingkan dengan nilai aktual. Hasil prediksi kemudian divisualisasikan dan dibandingkan dengan data historis untuk mengevaluasi seberapa baik model dapat mengikuti pola dalam data.

4. HASIL DAN PEMBAHASAN

Menghitung prediksi harga indeks *Dollar* dari tahun 2019-2024 menggunakan jaringan saraf tiruan *Backpropagation* yang dilakukan melalui tahapan-tahapan untuk memperoleh hasil evaluasi yang mendekati akurat.

4.1. Pengumpulan dan Pengolahan Data

4.1.1. Pengumpulan Data

Data yang digunakan untuk perhitungan prediksi menggunakan data dari dataset yang berada di web kaggle. Terdapat beberapa macam atribut antara lain: *Date* adalah tanggal yang mencakup periode dari tahun 2001 hingga 2022, *Price* adalah Nilai aktual indeks *Dollar* pada tanggal tertentu, *Open* adalah Nilai pembukaan indeks *Dollar* pada tanggal tertentu, *High* adalah Nilai tertinggi indeks *Dollar* pada tanggal tertentu, *Low* adalah Nilai terendah indeks *Dollar* pada tanggal tertentu, *Change %* adalah Perubahan persentase nilai indeks *Dollar* dari hari sebelumnya. Dataset tahun 2019 pada tabel 1, tahun 2020 tabel 2, dan tahun 2021 tabel 3.

Tabel 1: Dataset Pada Tahun 2019

Date	Price	Open	High	Low	Change%
01/01/2019	9617	9615	9632	9565	0
02/01/2019	9682	9614	9696	9582	0,68
....
30/12/2019	9674	9702	9702	9661	-0,19
31/12/2019	9639	9673	9673	9636	-0,36

Tabel 2: Dataset Pada Tahun 2020

Date	Price	Open	High	Low	Change%
01/01/2020	9639	965	971	9639	0
02/01/2020	9685	9648	9687	9642	0,48
....
30/12/2020	8968	8998	8998	8956	-0,35
31/12/2020	8994	8961	8998	8952	0.29

Tabel 3: Dataset Pada Tahun 2021

Date	Price	Open	High	Low	Change%
01/01/2021	8994	8993	8994	8993	0
04/01/2021	8987	8993	8994	8942	-0,08
....
30/12/2019	9597	9589	9622	9586	0,04
31/12/2019	9597	9599	9611	9557	0

4.1.2. Pengolahan Data

Dari beberapa atribut yang didapat dari pengumpulan data sebelumnya dilakukan proses pengolahan data dengan menghapus beberapa atribut yang tidak dipakai hasil dari pengolahan data yang didapat seperti pada gambar 3.

	2019	2020	2021
JANUARI	95.97	97.40	90.24
FEBRUARI	96.48	98.86	90.64
MARET	96.78	98.84	91.99
APRIL	97.37	99.89	91.65
MEI	97.73	99.58	90.30
JUNI	96.80	97.08	91.04
JULI	97.34	95.58	92.51
AGUSTUS	98.00	93.05	92.80
SEPTEMBER	98.61	93.41	92.95
OKTOBER	98.17	93.40	93.95
NOVEMBER	98.08	92.60	95.34
DESEMBER	97.38	90.51	96.21

Gambar 3. Hasil Pengolahan Data

4.2. Pembuatan Model JST

Model JST yang dibangun menggunakan *Sequential* terdiri dari beberapa lapisan (layer) yang terhubung secara berurutan.

4.2.1. Forward Propagation (Propagasi Maju)

Untuk data input x dengan bentuk (nsteps,), kita menghitung output model melalui dua lapisan. Lapisan Pertama (Hidden Layer): Fungsi Rumus 3 Aktivasi ReLU:

$$h_1 = \text{ReLU}(W_1x + b_1) \quad (3)$$

Keterangan sebagai berikut[15] : W_1 adalah matriks bobot untuk lapisan pertama, berukuran $50 \times n_{\text{steps}}$, b_1 adalah vektor bias untuk lapisan pertama, berukuran 50, x adalah input dengan ukuran (n_{steps}), h_1 adalah output dari lapisan pertama, berukuran (50),

4.2.2. Lapisan Kedua (Output Layer):

- Rumus 4 Output Model

$$y_{\text{pred}} = W_2h_2 + b_2 \quad (4)$$

Keterangan sebagai berikut[16]: W_2 adalah matriks bobot untuk lapisan output, berukuran 1×50 , b_2 adalah vektor bias untuk lapisan output, berukuran 1, h_1 adalah output dari lapisan pertama, berukuran (50), y_{pred} adalah prediksi model, berukuran (1,).

4.2.3. Kesimpulan

Model ini terdiri dari: Lapisan Tersembunyi: Memiliki 50 neuron dengan fungsi aktivasi ReLU, menerima input dengan bentuk (n_{steps}) dan menghasilkan output (50). Lapisan Output: Memiliki 1 neuron yang menghasilkan output akhir dari model.

4.3. Pelatihan Model JST

Pelatihan model dilakukan menggunakan algoritma *Backpropagation* dengan optimasi Adam (*Adaptive Moment Estimation*). Model dilatih selama 100 epoch dengan batch size sebesar 32. Selama pelatihan, model belajar meminimalkan *loss function* yang diukur menggunakan *Mean Squared Error* (MSE). Data dibagi menjadi 80% untuk data latih dan 20% untuk data uji, dengan evaluasi dilakukan pada setiap epoch untuk memantau kinerja model. Hasil dari perhitungan dengan rumus JST Forecasting

```
# Data
data = {
    '2019': [95.97, 96.48, 96.78, 97.37, 97.73, 96.88, 97.34, 98.00, 98.61, 98.17, 98.08, 97.38],
    '2020': [97.40, 98.86, 98.84, 99.89, 99.58, 97.08, 95.58, 93.05, 93.41, 93.40, 92.60, 90.51],
    '2021': [90.24, 90.64, 91.99, 91.65, 90.30, 91.04, 92.51, 92.80, 92.95, 93.95, 95.34, 96.21]
}
index = ['JANUARI', 'FEBRUARI', 'MARET', 'APRIL', 'MEI', 'JUNI', 'JULI', 'AGUSTUS', 'SEPTEMBER', 'OKTOBER', 'NOVEMBER', 'DESEMBER']
df = pd.DataFrame(data, index=index)

# Flatten dan normalisasi data
scaler = MinMaxScaler()
data_flattened = df.values.flatten()
data_normalized = scaler.fit_transform(data_flattened.reshape(-1, 1))

# Fungsi untuk membuat dataset
def create_dataset(data, look_back=3):
    X, y = [], []
    for i in range(len(data) - look_back):
        X.append(data[i:i + look_back])
        y.append(data[i + look_back])
    return np.array(X), np.array(y)

# Membuat dataset
look_back = 3
X, y = create_dataset(data_normalized, look_back)

# Membuat model
model = Sequential([
    Dense(64, activation='relu', input_shape=(look_back,)),
    Dense(32, activation='relu'),
    Dense(1)
])
```

Gambar 4. Proses perhitungan

```
model.compile(optimizer=Adam(learning_rate=0.001), loss='mse')

# Melatih model
history = model.fit(X, y, epochs=100, batch_size=32, validation_split=0.2, verbose=0)

# Fungsi untuk melakukan prediksi
def predict_next(model, data, look_back):
    prediction = model.predict(data[-look_back:].reshape(1, -1))
    return prediction[0, 0]

# Memprediksi 2024
predictions_2024 = []
last_sequence = data_normalized[-look_back:]

for _ in range(12):
    next_pred = predict_next(model, last_sequence, look_back)
    predictions_2024.append(next_pred)
    last_sequence = np.append(last_sequence[1:], next_pred)

# Denormalisasi hasil prediksi
predictions_2024 = scaler.inverse_transform(np.array(predictions_2024).reshape(-1, 1))

# Menambahkan hasil prediksi ke DataFrame
df['2024_prediksi'] = predictions_2024.flatten()

# Menampilkan hasil
print(df)
```

Gambar 5. Proses perhitungan

```
# Visualisasi hasil
plt.figure(figsize=(12, 6))
for year in df.columns:
    plt.plot(df.index, df[year], marker='o', label=year)
plt.title('Data Tahunan dan Prediksi 2024')
plt.xlabel('Bulan')
plt.ylabel('Nilai')
plt.legend()
plt.xticks(rotation=45)
plt.tight_layout()
plt.show()
```

Gambar 6. Proses perhitungan

Kode pada Gambar 4, Gambar 5, Gambar 6 menggunakan data nilai bulanan dari tahun 2019 hingga 2021, yang dinormalisasi dan digunakan untuk melatih model Jaringan Syaraf Tiruan (JST). Model dibuat menggunakan Keras dengan lapisan Dense dan aktivasi relu, kemudian dilatih dengan data yang telah disiapkan. Setelah pelatihan, model digunakan untuk memprediksi nilai bulanan tahun 2024 berdasarkan data sebelumnya. Hasil prediksi kemudian dinormalisasi kembali ke skala aslinya dan ditambahkan ke DataFrame. Akhirnya, data dari tahun 2019 hingga 2021 serta prediksi tahun 2024 divisualisasikan dalam grafik untuk memudahkan analisis.

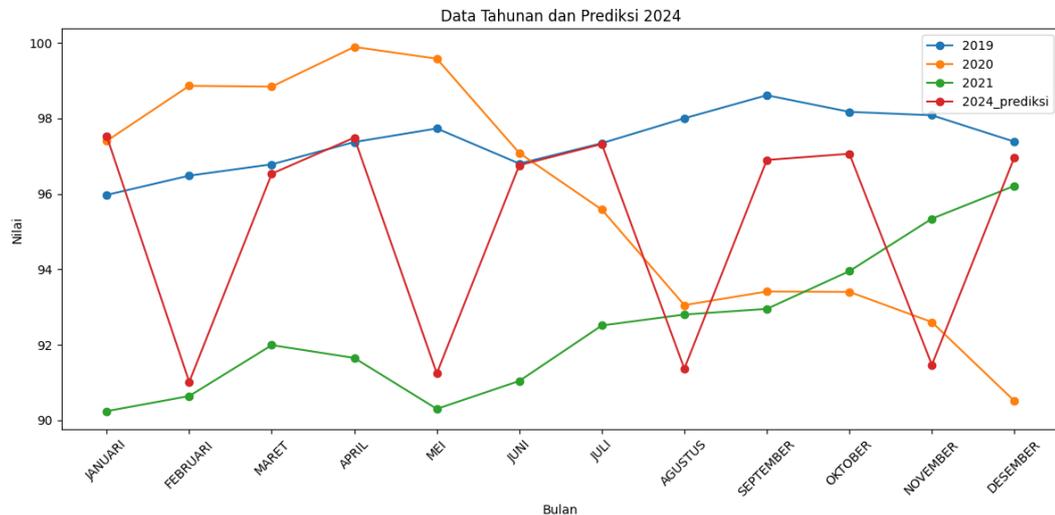
4.4. Hasil Evaluasi Model

```
# Evaluasi model
loss = model.evaluate(X_test, y_test, verbose=0)
print(f'Model Loss: {loss}')
```

Gambar 7. Proses Hasil Evaluasi

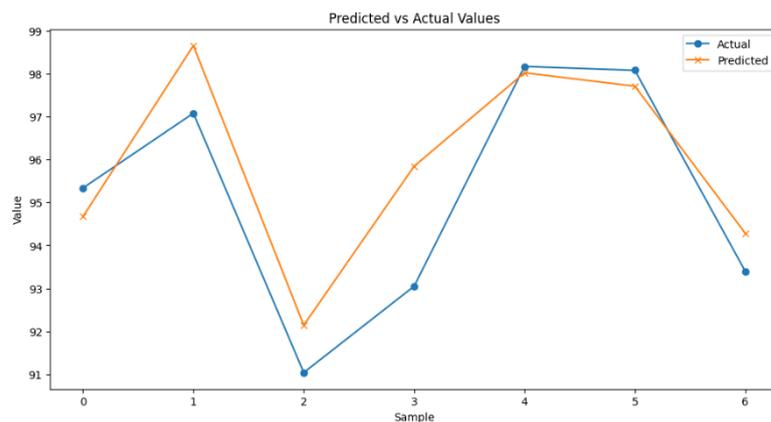
Kode pada Gambar 7 tersebut mengevaluasi kinerja model machine learning pada data uji menggunakan `model.evaluate(X_test, y_test, verbose=0)`, yang mengembalikan nilai loss (kerugian) sebagai indikasi seberapa baik model memprediksi data uji. Nilai loss

ini kemudian ditampilkan dengan perintah `print(f'Model Loss: {loss}')`. Loss yang lebih rendah menunjukkan performa model yang lebih baik.



Gambar 8. Perbandingan Data

Grafik Gambar 8 tersebut menunjukkan perbandingan data bulanan dari tahun 2019 hingga 2021 serta prediksi untuk tahun 2024. Sumbu x mewakili bulan, sementara sumbu y menunjukkan nilai terkait. Setiap garis berwarna—biru untuk 2019, oranye untuk 2020, hijau untuk 2021, dan merah untuk prediksi 2024—menggambarkan perubahan nilai dari bulan ke bulan. Secara umum, data 2019 dan 2021 lebih stabil, dengan variasi kecil (sekitar $\pm 2\%$), sementara data 2020 dan prediksi 2024 menunjukkan fluktuasi yang lebih besar. Prediksi 2024 sangat fluktuatif, dengan perubahan signifikan di beberapa bulan (sekitar $\pm 8\%$).



Gambar 9. Prediksi dan Aktual

Model prediksi mampu menghasilkan nilai yang cukup mendekati nilai aktual untuk sebagian besar sampel, meskipun terdapat beberapa perbedaan pada beberapa titik. Nilai MSE 26.314 dan persentase error sebesar 5.104% mendukung kesimpulan bahwa model memiliki performa yang baik seperti pada grafik Gambar 9.

5. KESIMPULAN

Proyek ini berhasil mengimplementasikan jaringan saraf tiruan (ANN) untuk memprediksi harga *Dollar* berdasarkan data historis, menunjukkan kemampuan yang baik dalam menangkap pola-pola kompleks pada data. Model ini diuntungkan dengan pengolahan data yang tepat dan meningkatkan efisiensi pembelajaran. Evaluasi model dengan metrik *Mean Squared Error* (MSE) menghasilkan nilai 26.314 dan persentase error sebesar 5.104%, menunjukkan bahwa model ini memberikan prediksi yang cukup akurat dan dapat digunakan sebagai alat yang berguna untuk analisis prediktif dalam domain ini.

DAFTAR PUSTAKA

- [1] I. Ilmi Laduni, F. Ekonomi dan Bisnis, I. Ilmi Laduni Ekonomi Keuangan Perbankan, and U. Brawijaya, "PENULIS KORESPONDENSI PENGARUH INSTRUMEN DERIVATIF MINYAK MENTAH, INDEKS *DOLLAR* AS, INDEKS SAHAM UNGGULAN, SUKU BUNGA FED DAN INFLASI AS TERHADAP HARGA FUTURES EMAS: ANALISIS PERIODE 2012-2021," *CONTEMPORARY STUDIES IN ECONOMIC*, vol. 1, 2022, doi: 10.21776/csefb.2022.01.4.14.
- [2] A. Rahmawati, D. Asih, I. Maruddani, and A. Hoyyi, "STRUCTURAL VECTOR AUTOREGRESSIVE UNTUK ANALISIS DAMPAK SHOCK NILAI TUKAR RUPIAH TERHADAP *DOLLAR* AMERIKA SERIKAT PADA INDEKS HARGA SAHAM GABUNGAN," *JURNAL GAUSSIAN*, vol. 6, no. 3, pp. 291–302, 2017, [Online]. Available: <http://ejournal-s1.undip.ac.id/index.php/gaussian>
- [3] E. Fausa, "Beberapa Aspek dalam Perkembangan Teknologi Informasi."
- [4] B. Badieah, R. Gernowo, and B. Surarso, "Metode Jaringan Syaraf Tiruan Untuk Prediksi Performa Mahasiswa Pada Pembelajaran Berbasis Problem Based Learning (PBL)," *JURNAL SISTEM INFORMASI BISNIS*, vol. 6, no. 1, p. 46, Nov. 2016, doi: 10.21456/vol6iss1pp46-58.
- [5] J. Teknologi dan Sistem Komputer, K. Undip Tembalang, J. Sudarto, and A. Pendidikan Tinggi Ilmu Komputer Indonesia, "Volume 6 Nomor 1 Tahun 2018 Didukung oleh", [Online]. Available: <http://jtsiskom.undip.ac.id/index.php/jtsiskom>
- [6] G. Safet, Y. Raharjo, R. Febrian Umbara, and D. Triantoro, "PERAMALAN NILAI TUKAR RUPIAH TERHADAP *DOLLAR* AMERIKA MENGGUNAKAN JARINGAN SYARAF TIRUAN (p,d,q)."
- [7] A. P. Windarto, M. R. Lubis, and S. Solikhun, "Implementasi JST pada Prediksi Total Laba Rugi Komprehensif Bank Umum dan Konvensional dengan *Backpropagation*," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 4, pp. 411–418, Oct. 2018, doi: 10.25126/jtiik.201854767.
- [8] I. Agustina, Y. Mulyani, T. Septiana, and M. Mardiana, "ANALISIS PENGEMBANGAN MODEL PREDIKSI KESUKSESAN KICKSTARTER MENGGUNAKAN ALGORITMA *BACKPROPAGATION* DAN *RANDOM FOREST*," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 10, no. 3, Aug. 2022, doi: 10.23960/jitet.v10i3.2742.
- [9] Y. Seruni and N. A. Rizal, "SEIKO : Journal of Management & Business Pengaruh Harga Imbal Hasil Obligasi, Indeks *Dollar*, Tingkat Inflasi, dan Suku Bunga Amerika Serikat terhadap Harga Emas Kontrak Berjangka pada Investasi Gold Loco London pada Masa Pandemi Covid-19," *SEIKO : Journal of Management & Business*, vol. 6, no. 2, pp. 329–338, 2023.

- [10] R. Ernayani, "Pengaruh Kurs *Dollar*, Indeks Dow Jones Dan Tingkat Suku Bunga SBI Terhadap IHSG (Periode Januari 2005-Januari 2015)."
- [11] N. P. Sakinah, I. Cholissodin, and A. W. Widodo, "Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 7, pp. 2612–2618, 2018, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/1658>
- [12] T. W. Khusniyah and S. Sutikno, "Prediksi Nilai Tukar Petani Menggunakan Jaringan Syaraf Tiruan Backpropagation," *Sci. J. Informatics*, vol. 3, no. 1, pp. 11–18, 2016, doi: 10.15294/sji.v3i1.4970.
- [13] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [14] "UJM 2 (2) (2013) UNNES Journal of Mathematics," 2013, [Online]. Available: <http://journal.unnes.ac.id/sju/index.php/ujm>
- [15] J. Schmidt-Hieber, "Nonparametric regression using deep neural networks with relu activation function," *Ann Stat*, vol. 48, no. 4, pp. 1875–1897, Aug. 2020, doi: 10.1214/19-AOS1875.
- [16] Q. V Le, "A Tutorial on Deep Learning Part 1: Nonlinear Classifiers and The Backpropagation Algorithm," 2015.