

**PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* DALAM
MEMPREDIKSI KURS RUPIAH TERHADAP EURO**

(Skripsi)

**Oleh
AMELIA FALLIZIA PUTRI
1857031014**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

ABSTRACT

IMPLEMENTATION OF ARTIFICIAL NEURAL NETWORK METHOD TO PREDICT EXCHANGE CURRENCY RUPIAH AGAINST EURO

By

Amelia Fallizia Putri

This research predicts the exchange currency of Rupiah against Euro using the Artificial Neural Network (ANN) method with Backpropagation Algorithm. This research uses two variables, sell rate currency and buy rate currency from January 1st 2020 until June 30th 2021. The best model in this method that is split into 90% training data and 10% testing data will be chosen by some of the optimal parameters using hypertuning. The optimal parameters result of hypertuning for the artificial neural network method with backpropagation are using input layer with 10 nodes, 2 hidden layers with 19 nodes and 13 nodes, output layer with 1 node, dropout 0.2, epoch 100, batch size 32, and activation function using TanH. Prediction results for sale rate and buy rate Rupiah currency against Euro currency have MAPE values 0.0059% and 0.0053%, which means these results have good predictive ability with accuracy values 99.994% for sell rate currency, and 99.994% for buy rate currency. Therefore, this method is great for doing sale rate and buy rate Rupiah currency against Euro forecast in the future.

Keywords: Exchange Currency, Data Mining, Machine Learning, Artificial NeuralNetwork, Backpropagation Algorithm.

ABSTRAK

PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* DALAM MEMPREDIKSI KURS RUPIAH TERHADAP EURO

Oleh

Amelia Fallizia Putri

Penelitian ini memprediksi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€) menggunakan metode *Artificial Neural Network* (ANN) dengan Algoritma *Backpropagation*. Variabel yang digunakan dalam penelitian ini ada dua, yaitu kurs jual dan kurs beli untuk periode 1 Januari 2020 sampai dengan 30 Juni 2021. Pemilihan model terbaik dengan skema 90% *training data* dan 10% *testing data* dilakukan dengan *hypertuning* untuk memperoleh parameter yang optimal. Nilai parameter optimal yang diperoleh, yaitu *input layer* dengan 10 *nodes*, 2 *hidden layers* dengan 19 *nodes* dan 13 *nodes*, *output layer* dengan 1 *node*, *dropout* sebesar 0.2, *batch size* sebesar 32, *epoch* sebesar 100, dan fungsi aktivasi *TanH*. Hasil prediksi pada kurs jual dan kurs beli Rupiah terhadap Euro diperoleh nilai MAPE sebesar 0.0059%, dan 0.0053%, sehingga dapat diartikan bahwa hasil tersebut memiliki kemampuan prediksi yang baik dengan nilai akurasi sebesar 99.994% untuk kurs jual, dan sebesar 99.994% untuk kurs beli. Oleh karena itu, metode ini sangat baik digunakan untuk meramal kurs jual dan kurs beli Rupiah terhadap Euro.

Kata kunci: Nilai Tukar Mata Uang, *Data Mining*, *Machine Learning*, *Artificial Neural Network*, Algoritma *Backpropagation*.

**PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* DALAM
MEMPREDIKSI KURS RUPIAH TERHADAP EURO**

Oleh

Amelia Fallizia Putri

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA**

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

Judul Skripsi : **PENERAPAN METODE ARTIFICIAL NEURAL NETWORK DALAM MEMPREDIKSI KURS RUPIAH TERHADAP EURO**

Nama Mahasiswa : **Amelia Fallizia Putri**

Nomor Pokok Mahasiswa : **1857031014**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



Ir. Warsono, M.S., Ph.D.
NIP 19630216 198703 1 003

Dr. Notiragayu, S.Si., M.Si.
NIP 19731109 200012 2 001

2. Ketua Jurusan Matematika

Dr. Aang Nuryaman, S.Si., M.Si.
NIP 19740316 200501 1 001

MENGESAHKAN

1. Tim Penguji

Ketua : Ir. Warsono, M.S., Ph.D.



Sekretaris : Dr. Notiragayu, S.Si., M.Si.



**Penguji
Bukan Pembimbing : Dian Kurniasari, S.Si., M.Sc.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Satripto Dwi Yuwono, S.Si., M.T.
NIP 19740705 200003 1 001

Tanggal Lulus Ujian Skripsi : 21 Juli 2022

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : **Amelia Fallizia Putri**

Nomor Pokok Mahasiswa : **1857031014**

Jurusan : **Matematika**

Judul Skripsi : **PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* DALAM MEMREDIKSI KURS RUPIAH TERHADAP EURO**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan apabila kemudian hari terbukti bahwa skripsi ini merupakan salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, Juli 2022
Penulis



Amelia Fallizia Putri

RIWAYAT HIDUP

Penulis bernama Amelia Fallizia Putri dilahirkan di Jakarta pada 30 Juni 2000. Penulis merupakan anak pertama dari tiga bersaudara pasangan Bapak Andi Hasanudin dan Ibu Viane Maritje Tumewu.

Penulis pertama kali menempuh pendidikannya di Taman Kanak-Kanak R.A Al-Asyiroh pada tahun 2004-2006 dan melanjutkan pendidikannya ke Sekolah Dasar di SD Labschool Rawamangun Jakarta pada tahun 2006-2012. Kemudian, penulis melanjutkan jenjang pendidikannya di SMP Negeri 92 Jakarta pada tahun 2012-2015. Jenjang pendidikan selanjutnya di SMA Negeri 10 Bandar Lampung pada tahun 2015-2018.

Pada tahun 2018 penulis diterima sebagai mahasiswa S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Mandiri Masuk Perguruan Tinggi Negeri (SMMPN). Selama menjadi mahasiswa penulis juga aktif dalam berorganisasi AIESEC in Lampung University. Pada tahun 2018 penulis menjadi *volunteer* pada Asian Para Games Indonesia sebagai *International Relation Protocol Volunteer*, kemudian pada tahun 2021 penulis melakukan Kuliah Kerja Nyata (KKN) di Kelurahan Batu Putuk, Kecamatan Teluk Betung Utara, Kota Bandar Lampung dan Kerja Praktik (KP) di Badan Kependudukan dan Keluarga Berencana (BKKBN) Provinsi Lampung, serta mengikuti Program Kampus Merdeka yang bernama Magang Bersertifikat di PT Global Intra Talenta (Glints Indonesia) sebagai *front-end web developer* dan *UI/UX designer* di PT Intermedia Multibahasa Indonesia (*LingoTalk*).

KATA INSPIRASI

Sesungguhnya Allah tidak merubah keadaan sesuatu kaum sehingga mereka merubah keadaan yang ada pada diri mereka sendiri.

(Q.S. Al-Ra'd: 11)

Ketahuiilah bahwa kemenangan bersama kesabaran, kelapangan bersama kesempatan, dan kesulitan bersama kemudahan

(HR. Tirmidzi)

There is no elevator to success, so you have to take the stairs

(Zig Ziglar)

Don't be scared to start new things, even mistakes are lessons for success

(Penulis)

PERSEMBAHAN

Dengan mengucap puji dan syukur atas kehadiran Allah SWT, atas segala rahmat dan hidayah-Nya skripsi ini dapat terselesaikan dengan baik, serta salawat serta salam kepada junjungan kita Nabi Muhammad SAW. Dengan penuh ketulusan saya persembahkan karya tulis ini untuk:

Bapak Andi Hasanudin dan Ibu Viane Maritje Tumewu

Terima kasih kepada kedua orang tua saya yang selalu memberikan dukungan dan saran dalam setiap keputusan, kasih sayang serta doa yang tak pernah putus dalam setiap langkah yang saya tempuh

Adik Annisa Pingkanni Putri dan Atha Fahim Khairan

Terima kasih telah memberikan doa, semangat, serta dukungan selama ini

Dosen Pembimbing dan Pembahas

Terima kasih kepada bapak dan ibu dosen yang sangat berjasa, membantu, memberikan arahan, serta masukan dan ilmu yang bermanfaat

Teman-teman yang telah membantu, menemani, serta mendukung setiap langkahnya dari awal, hingga saat ini, dan seterusnya;

Almamater Tercinta, Universitas Lampung

SANWACANA

Puji dan syukur penulis panjatkan kehadirat Allah SWT karena berkat segala rahmat dan karunia-Nya penulis dapat menyelesaikan skripsi dengan judul “Penerapan Metode *Artificial Neural Network* Untuk Memprediksi Kurs Rupiah terhadap Euro”.

Dalam menyusun laporan ini penulis banyak mendapatkan bantuan. Oleh karena itu, penulis mengucapkan terimakasih sebesar-besarnya kepada:

1. Bapak Ir. Warsono, M.S., Ph.D., selaku Dosen Pembimbing I yang telah bersedia membimbing, memberi saran, bantuan, motivasi, dan arahan dalam menyelesaikan skripsi ini.
2. Ibu Dr. Notiragayu, S.Si., M.Si., selaku Pembimbing II yang telah memberikan saran serta masukan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Ibu Dian Kurniasari, S.Si., M.Sc., selaku dosen penguji yang telah memberikan kritik dan saran selama proses penyusunan skripsi.
4. Ibu Widiarti, S.Si., M.Si., selaku dosen Pembimbing Akademik.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika.
6. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh dosen, staff, karyawan Jurusan Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Mama dan Papa, adik-adik, dan keluarga besar yang selalu mendoakan dan memberikan dukungan.
9. Deprin, Aya, Ayi, Djanah, Kiming, Aisya, Panka sahabat yang selalu ada dan memberikan dukungan.

10. Cilmutuyul, Elsakibo, Markisut, Repisang, Ajeng, Ipeh, Eja dan Kelas C 2018 yang memberi dukungan selama kuliah.
11. Adel, Ellen, Salma, Mitha, Ejum, Amelcil, Regis, Andre, Addin teman baik yang selalu memberikan canda dan tawa.
12. Dini, Anjeng, Nina, Waliyyan, Nabil teman KKN Batu Putuk yang telah memberikan dukungan.
13. Semua pihak yang telah membantu dalam menyelesaikan skripsi ini yang tidak bisa penulis sebutkan satu persatu.

Penulis menyadari masih banyak kekurangan dalam laporan ini. Oleh karena itu, kritik dan saran sangat diharapkan agar dapat menjadi pelajaran dan perbaikan untuk kedepannya. Semoga skripsi ini dapat memberikan manfaat baik bagi penulis maupun bagi pihak yang membutuhkan.

Bandar Lampung, Juli 2022
Penulis,

Amelia Fallizia Putri

DAFTAR ISI

halaman

DAFTAR TABEL	iii
DAFTAR GAMBAR.....	iv
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Tujuan Penelitian	4
1.3 Manfaat Penelitian	4
II. TINJAUAN PUSTAKA.....	5
2.1 Prediksi	5
2.2 Data Deret Waktu (<i>Time Series</i>)	5
2.3 <i>Machine Learning</i>	6
2.4 <i>Python</i>	8
2.5 <i>Artificial Neural Network</i> (ANN)	8
2.5.1 Pengertian <i>Artificial Neural Network</i> (ANN).....	8
2.5.2 Komponen-Komponen <i>Artificial Neural Network</i>	9
2.5.3 Arsitektur <i>Artificial Neural Network</i>	10
2.6 <i>Artificial Neural Network</i> dengan Algoritma <i>Backpropagation</i>	12
2.7 Membangun Model <i>Artificial Neural Network</i>	14
2.7.1 <i>Hidden dan Nodes Layer</i>	14
2.7.2 <i>Dropout</i>	15
2.7.3 <i>Epoch dan Batch Size</i>	16
2.7.4 Fungsi Aktivasi.....	16
2.7.5 <i>Hyperparameter Optimizer</i>	18
2.8 Validasi Model.....	19
III. METODOLOGI PENELITIAN	21
3.1 Waktu dan Tempat	21
3.2 Data Penelitian	21
3.3 Metode Penelitian	22
IV. HASIL DAN PEMBAHASAN	25
4.1 Pengumpulan Data	25
4.2 <i>Input Data</i>	26
4.3 Visualisasi Data.....	28

4.4	<i>Pre-processing</i> Data.....	28
	4.4.1 Data Hilang.....	28
	4.4.2 <i>Outlier</i>	29
	4.4.3 Data <i>Slicing</i>	30
	4.4.4 Data <i>Scaling</i>	30
4.5	Pembagian Data <i>Training</i> dan Data <i>Testing</i>	31
4.6	Membangun Model <i>Artificial Neural Network</i> (ANN) menggunakan Algoritma <i>Backpropagation</i>	32
4.7	Pengujian Model	34
4.8	Prediksi	38
	4.8.1 Denormalisasi Data	38
	4.8.2 Hasil Prediksi Kurs Jual dan Kurs Beli Rupiah terhadap Euro	39
4.9	Evaluasi Model ANN.....	44
V.	KESIMPULAN	45
	DAFTAR PUSTAKA.....	46

LAMPIRAN

DAFTAR TABEL

Tabel	halaman
1. Data Kurs Jual dan Kurs Beli Rupiah terhadap Euro.....	22
2. Data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro (Sebelum diolah)	25
3. Data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro (Sesudah diolah)	26
4. Data <i>Input</i> Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro	27
5. Data Hilang pada Data Kurs Jual dan Kurs Beli Rupiah terhadap Euro.....	29
6. Hasil Data <i>Scaling</i>	30
7. Pembagian Data Training dan Data Testing	31
8. Parameter yang digunakan dalam model <i>Artificial Neural Network</i> (Skema 70% <i>training</i> & 30% <i>testing</i>)	32
9. Parameter yang digunakan dalam model <i>Artificial Neural Network</i> (Skema 80% <i>training</i> & 20% <i>testing</i>)	33
10. Parameter yang digunakan dalam model <i>Artificial Neural Network</i> (Skema 90% <i>training</i> & 10% <i>testing</i>)	33
11. Perbandingan Data Aktual dengan Data Hasil Prediksi Kurs Jual dan Kurs Beli Rupiah terhadap Euro Skema 70% <i>training</i> & 30% <i>testing</i>	42
12. Perbandingan Data Aktual dengan Data Hasil Prediksi Kurs Jual dan Kurs Beli Rupiah terhadap Euro Skema 80% <i>training</i> & 20% <i>testing</i>	43
13. Perbandingan Data Aktual dengan Data Hasil Prediksi Kurs Jual dan Kurs Beli Rupiah terhadap Euro Skema 90% <i>training</i> & 10% <i>testing</i>	43
14. Evaluasi Model ANN Skema 70% <i>training</i> & 30% <i>testing</i>	44
15. Evaluasi Model ANN Skema 80% <i>training</i> & 20% <i>testing</i>	44
16. Evaluasi Model ANN Skema 90% <i>training</i> & 10% <i>testing</i>	44

DAFTAR GAMBAR

Gambar	halaman
1. Arsitektur <i>Artificial Neural Network</i>	9
2. Struktur <i>Neuron Artificial Neural Network</i>	9
3. Struktur <i>Single Layer Network</i>	11
4. Struktur <i>Multi Layer Network</i>	11
5. Struktur <i>Competitive Layer Network</i>	12
6. Arsitektur <i>Artificial Neural Network Backpropagation</i>	14
7. Perbandingan <i>Neural Network</i> tanpa <i>Dropout</i> dan Setelah Menggunakan <i>Dropout</i>	15
8. Fungsi Aktivasi <i>ReLU</i>	17
9. Fungsi aktivasi <i>Sigmoid</i>	17
10. Fungsi aktivasi <i>TanH</i>	18
11. Data <i>Input</i> Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro	27
12. Plot Data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro	28
13. Box Plot Data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro	29
14. Data <i>Slicing</i> Kurs Jual dan Kurs Beli	30
15. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>)	34
16. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>)	34
17. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>)	35

18. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 80% <i>training</i> & 20% <i>testing</i>).....	35
19. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 80% <i>training</i> & 80% <i>testing</i>).....	36
20. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 80% <i>training</i> & 20% <i>testing</i>).....	36
21. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	37
22. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	37
23. Grafik <i>Loss</i> Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	38
24. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>).....	39
25. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>).....	39
26. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 70% <i>training</i> & 30% <i>testing</i>).....	39
27. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 80% <i>training</i> & 20% <i>testing</i>).....	40
28. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 80% <i>training</i> & 20% <i>testing</i>).....	40
29. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 80% <i>training</i> & 20% <i>testing</i>).....	40
30. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>Sigmoid</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	41
31. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>ReLU</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	41
32. Plot Perbandingan Data Aktual dengan Data Prediksi Kurs Jual dan Kurs Beli (Fungsi Aktivasi <i>TanH</i> dengan Skema 90% <i>training</i> & 10% <i>testing</i>).....	41

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Virus menular penyebab infeksi saluran pernapasan yang ditemukan pertama kali di Wuhan, Cina pada Desember tahun 2019 dan diberi nama secara resmi oleh WHO sebagai *Coronavirus Disease in 2019* atau COVID-19 (World Health Organization, 2020). Kepala WHO tahun 2020, Tedros Adhanom Ghebreyesus, menyatakan bahwa penyebaran virus COVID-19 yang begitu cepat di dunia memutuskan WHO untuk menetapkan COVID-19 sebagai pandemi dunia secara resmi pada 11 Maret 2020 dan Eropa sebagai pusat pandemi COVID-19, dikarenakan Eropa melaporkan kasus kematian lebih banyak daripada kasus kematian di dunia selain Cina. Pandemi global COVID-19 mengakibatkan problematika baru di berbagai negara khususnya pada dua ruang lingkup, yaitu setiap tingkatan aktor (*level of analysis*) dan berbagai aspek kehidupan (*aspects or issues*). Salah satu dampak dari aspek kehidupan adalah dibidang ekonomi, terlihat jelas pada pasar valuta asing terutama harga nilai tukar mata uang Euro Eropa di awal tahun 2020 yang mengalami penurunan dan kenaikan signifikan.

Volatilitas nilai tukar adalah salah satu jenis pasar yang memperdagangkan valuta asing suatu negara terhadap valuta asing negara lainnya atau biasa disebut pasar valuta asing. Peningkatan dan penurunan dalam perdagangan pasar valuta asing mengakibatkan terjadinya peningkatan volatilitas yang substansial. Baxter dan Stockman (1989), menyatakan bahwa peningkatan volatilitas nilai tukar memiliki dampak signifikan terhadap tingkat inflasi suatu negara, serta menghambat perdagangan internasional dan investasi internasional. Artinya, pasar valuta asing

merupakan pasar yang volatil. Data deret waktu mengandung volatil apabila formulasi data deret waktu selalu berubah atau pola data memiliki tingkat kesulitan yang tinggi untuk dibuat model formulasinya, sehingga hasil ramalan atau prediksi dengan menggunakan metode statistik sebelumnya kurang memberikan hasil yang baik. Nilai tukar adalah salah satu data deret waktu yang terkenal sulit untuk dilakukan prediksi, hal ini dikarenakan kurs merupakan salah satu pasar yang sangat volatil (Yu dkk, 2007).

Prediksi merupakan proses untuk menemukan pola dari variabel masa depan menggunakan variabel masa lalu. *Time series* atau data deret waktu adalah perkiraan masa depan berdasarkan informasi atau kesalahan masa lalu dari suatu variabel (Makridakis dkk, 1999). Banyak metode data *time series* yang sering digunakan untuk melakukan peramalan, salah satunya yaitu metode *Autoregressive Integrated Moving Average* (ARIMA). Tetapi, metode ini memerlukan beberapa asumsi yang harus dipenuhi dan model ARIMA ini hanya bisa digunakan untuk data yang bersifat stasioner atau linear. Maka dari itu, metode ARIMA tidak dapat digunakan untuk memprediksi data volatil seperti nilai tukar mata uang asing. Seiring berkembangnya teknologi komputer dan semakin populernya kecerdasan buatan, peneliti dan praktisi menjadi lebih cenderung untuk mengadopsi *Artificial Neural Network* (ANN) sebagai metode alternatif *time series* dalam prediksi keuangan.

Artificial Neural Network (ANN) merupakan salah satu metode data *time series* yang dapat digunakan untuk melakukan prediksi. ANN adalah *node* atau jaringan yang saling berhubungan antar *nodes* atau simpul-simpul dan setiap hubungan tersebut mempunyai bobot koneksi yang dilatih untuk mencapai respon yang diinginkan. Setiap bobot koneksi dipropagasikan ke seluruh simpul atau *node*. Struktur *artificial neural network* terdiri dari tiga lapisan, yaitu *input layer*, *hidden layer*, dan *output layer*. Setiap *layer* diberikan pembobot untuk mentransformasi nilai *input* menjadi nilai *output* dan terdiri dari beberapa *neuron* yang terhubung dengan *neuron* lainnya pada *layer* terdekat (Ripley, 1996). Algoritma *backpropagation* merupakan prosedur yang paling populer, efektif, dan mudah

dipelajari pada jaringan *multilayer* yang kompleks untuk mengoptimalkan pelatihan ANN (Elarabi, 2014). *Backpropagation* melakukan pembelajaran terbimbing (*supervised learning*) yang digunakan pada jaringan *multilayer* terdiri dari beberapa *hidden layer* dengan tujuan untuk meminimalkan eror terhadap jaringan yang menghasilkan *output* (Hamid dkk, 2011).

Bedasarkan penelitian yang telah dilakukan oleh Khasei dan Bijari (2010) mengenai prediksi nilai tukar Poundsterling (£) terhadap Dolar Amerika (\$) menggunakan model *Artificial Neural Network* (ANN) menghasilkan akurasi sebesar 85,75%. Sehingga dapat disimpulkan bahwa penelitian ini memiliki tingkat akurasi yang cukup tinggi. Oleh karena itu, penelitian memprediksi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€) menggunakan metode *Artificial Neural Network* perlu dilakukan.

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini yaitu:

1. Mengimplementasikan metode *Artificial Neural Network* (ANN) dalam memprediksi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€).
2. Menentukan model terbaik untuk memprediksi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€).
3. Melakukan prediksi terhadap nilai tukar mata uang Rupiah (Rp) terhadap Euro (€) menggunakan metode *Artificial Neural Network* (ANN).
4. Mengetahui nilai akurasi untuk ketepatan metode *Artificial Neural Network* (ANN) pada data nilai tukar mata uang Rupiah (Rp) terhadap Euro (€).

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Memberikan pengetahuan terkait metode *Artificial Neural Network*.
2. Sebagai bahan rujukan pengembangan ilmu matematika dalam memprediksi realisasi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€) serta menjadi bahan pertimbangan dan memberikan informasi bagi peneliti yang akan melakukan penelitian tentang nilai tukar mata uang Rupiah (Rp) terhadap Euro (€).
3. Mengetahui nilai prediksi untuk realisasi nilai tukar mata uang Rupiah (Rp) terhadap Euro (€) menggunakan metode *Artificial Neural Network* (ANN) dan diharapkan dapat membantu *trader* pasar valuta asing dengan menggunakan asumsi prediksi harian.

II. TINJAUAN PUSTAKA

2.1 Prediksi

Prediksi adalah proses memperkirakan sesuatu yang akan terjadi di masa depan berdasarkan informasi yang tersedia saat ini. Prediksi tidak selalu memberikan jawaban yang pasti melainkan mencoba memberikan jawaban yang sedekat mungkin dengan kejadiannya (Kafil, 2019). Pada tahun 1999 Markridakis dkk menyatakan bahwa prediksi bertujuan untuk mengidentifikasi pola sistematis dan menemukan hubungan tren berdasarkan data historis. Pengumpulan data historis disini berperan sebagai tahap pertama yang dilakukan untuk suatu prediksi atau ramalan. Pengumpulan data historis tidak representatif atau dapat dikatakan tidak akurat dan tidak memadai, sehingga akan sangat mempengaruhi hasil prediksi yang kurang akurat. Semakin besar eror yang dihasilkan maka semakin tidak akurat hasil prediksi yang diperoleh.

2.2 Data Deret Waktu (*Time Series*)

Time series adalah sekumpulan data yang diperoleh dari suatu pengamatan kegiatan yang dilakukan pada interval suatu periode waktu dan dicatat secara berurutan menurut urutan kejadian pada interval waktu tertentu (Wei 2006). Hendikawati (2014) mengemukakan pendapat bahwa *time series* adalah prosedur statistika yang digunakan untuk memprediksi struktur *probabilistic* keadaan yang akan terjadi dimasa depan dalam pengambilan keputusan sebuah perencanaan tertentu.

Adapun kegiatan data *time series* untuk proses prediksi, melihat statistik data perusahaan/instansi, membandingkan suatu kejadian (keadaan) yang dilakukan antar pribadi maupun kelompok (perusahaan). Beberapa faktor yang mempengaruhi data *time series* diantaranya yakni:

- a. Pola *Trend* menunjukkan perubahan kenaikan dan penurunan dalam data.
- b. Pola Siklis menunjukkan perubahan data yang dipengaruhi oleh fluktuasi jangka panjang.
- c. Pola Musiman menunjukkan perubahan dalam data yang dipengaruhi faktor musiman atau waktu tahun.
- d. Pola *Random* menunjukkan perubahan data akibat kejadian tak terduga.

Time series memiliki ciri interval waktu antara indeks waktu t yang dapat dinyatakan dalam satuan waktu antara pengamat Z_t dengan Z_{t-k} . Salah satu tujuan terpenting dalam *time series* yaitu estimasi nilai masa depan. Bahkan tujuan akhir dari pemodelan *time series* adalah untuk mengontrol sistem operasi biasanya berdasarkan pada prediksi. Istilah prediksi lebih sering digunakan dalam literatur *time series* daripada prediksi jangka panjang (Wei, 2006).

2.3 Machine Learning

Machine Learning atau pembelajaran mesin adalah sebuah pendekatan dalam AI yang banyak digunakan untuk menggantikan atau meniru perilaku manusia untuk memecahkan masalah atau melakukan otomatisasi. *Machine Learning* berusaha meniru cara manusia atau makhluk intelektual dan menggeneralisasi proses. *Machine learning* setidaknya memiliki dua aplikasi, yaitu klasifikasi dan prediksi. Ciri khas dari pembelajaran mesin adalah adanya proses pelatihan, pembelajaran, atau *training*. Oleh karena itu, pembelajaran mesin memerlukan data untuk dipelajari yang disebut sebagai data *training*. Klasifikasi adalah metode dalam pembelajaran mesin yang digunakan oleh mesin untuk mengurutkan atau mengklasifikasikan objek berdasarkan karakteristik tertentu ketika manusia mencoba membedakannya satu sama lain. Sedangkan prediksi digunakan oleh

mesin untuk menyimpulkan *output* suatu data *input* berdasarkan data yang telah dipelajari pada pelatihan. Metode pembelajaran mesin yang paling populer adalah Sistem Pengambilan Keputusan, *Support Vector Machines* (SVM) dan *Neural Networks*.

Fausett (1994) menyatakan bahwa secara umum ada 2 metode algoritma pembelajaran, yaitu metode pembelajaran terawasi (*supervised learning*) dan metode pembelajaran tidak terawasi (*unsupervised learning*).

1. *Supervised Learning*

Metode ini digunakan ketika nilai *output* yang diinginkan sudah diketahui sebelumnya. Nilai *output* dari jaringan akan dibandingkan dengan nilai *output* targetnya yang dinamakan dengan galat atau eror. Ketika eror masih cukup besar artinya diperlukan pembelajaran lagi hingga didapatkan nilai eror yang kecil atau nilai *output* dari jaringan yang tidak berbeda jauh dengan nilai *output* target. Adapun contoh algoritma yang menggunakan metode pembelajaran terawasi (*supervised learning*) adalah *hebbian* (*hebb rule*), *perceptron*, *adaline*, *boltzman*, *hapfield*, dan *backpropagation*.

2. *Unsupervised Learning*

Metode pembelajaran tak terawasi (*unsupervised learning*) merupakan metode pembelajaran ketika tidak memerlukan acuan nilai *output* yang diharapkan. Pada metode ini tidak diketahui akan seperti apa nilai *output* yang diharapkan, melainkan hanya ditentukan nilai bobot pada suatu *range* sesuai nilai *input* yang digunakan. Penerapan metode ini seperti halnya klasifikasi, karena tujuan utama dari metode ini untuk mengelompokkan unit-unit yang memiliki kemiripan pada suatu area tertentu. Contoh algoritma yang menggunakan metode *unsupervised learning* adalah *competitive*, *hebbian*, *kohonen*, *LVQ* (*Learning Vector Quantization*), dan *neocognitron*.

2.4 Python

Python dikembangkan oleh Guido van Rossum di Belanda pada tahun 1990 dan dinamai dari acara televisi kesukaan Guido *Monty Python's Flying Circus*. Van Rossum mengembangkan *Python* sebagai hobi, kemudian *Python* telah menjadi bahasa pemrograman yang banyak digunakan di industri dan pendidikan karena sintaksnya yang sederhana, ringkas, intuitif dan memiliki pustaka yang luas (Schuerer dan Maufrais, 2010). *Python* adalah bahasa pemrograman tingkat tinggi yang diinterpretasikan yang dapat digunakan untuk berbagai keperluan (Sembiring dan Erfina 2020). *Python* memiliki metode pemrosesan ditafsirkan atau kode program tidak perlu dikompilasi dan dijalankan baris demi baris.

2.5 Artificial Neural Network (ANN)

2.5.1 Pengertian Artificial Neural Network (ANN)


Artificial Neural Network adalah sebuah sistem syaraf selular fisik yang dapat memperoleh, menyimpan, dan menggunakan pengetahuan yang telah didapat dari pengetahuan sebelumnya. Fausett (1994) menyatakan bahwa *Artificial Neural Network* dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi sebagai berikut:

1. Pemrosesan informasi dilakukan oleh banyak elemen sederhana (*neurons*).
2. Sinyal dikirim antar *neuron* melalui penghubung-penghubung.
3. Penghubung antar *neuron* memiliki bobot yang akan menambah atau mengurangi sinyal.
4. Untuk menentukan *output*, setiap *neuron* menggunakan fungsi aktivasi yang dikenakan pada penjumlahan input yang diterima. Besarnya *output* ini selanjutnya dibandingkan dengan suatu batas ambang.

dan *Artificial Neural Network* ditentukan oleh tiga hal, yakni:

1. Pola hubungan antar *neuron* (arsitektur jaringan).
2. Cara untuk menentukan bobot penghubung (metode *training/ learning/ algoritma*).
3. Fungsi aktivasi untuk penentuan *output*.


Informasi yang diteruskan ke jaringan syaraf tiruan yang dirambatkan melalui *layer neuron*, dimulai dari *layer input* hingga *layer output* melalui lapisan lainnya. Lapisan ini disebut lapisan tersembunyi (*hidden layer*). Berikut adalah arsitektur jaringan syaraf sederhana (Fausett, 1944).



Gambar 1. Arsitektur Jaringan Syaraf Tiruan. (Sumber: Fausett, 1994)

2.5.2 Komponen-Komponen *Artificial Neural Network*

Kusumadewi (2003) dalam penelitiannya mengatakan bahwa *artificial neural network* terdiri dari beberapa *neuron* dan terdapat penghubung *neuron* yang dikenal dengan bobot seperti halnya otak manusia.



Gambar 2. Struktur *Neuron Artificial Neural Network*. (Sumber: Kusumadewi, 2003)

Berdasarkan Gambar 2 dapat dijelaskan komponen-komponen *artificial neural network* sebagai berikut.


1. *Input* : seperti halnya dendrit pada otak manusia yang berfungsi sebagai penerima informasi masukan dari *neuron* lain.
2. *Neuron* : komponen yang bertugas untuk memproses informasi.
3. Bobot : seperti halnya sinopsis pada otak manusia yang memiliki fungsi yang sama untuk menunjukkan kekuatan hubungan antara *neuron* satu dengan yang lainnya.
4. Fungsi aktivasi : suatu nilai tertentu yang memetakan fungsi hasil penjumlahan yang diterima oleh semua *input* dari suatu *neuron*.
5. *Output* : sama halnya dengan *axon* pada otak manusia yang sama-sama berfungsi sebagai proses pembelajaran atau proses perhitungan suatu fungsi aktivasi yang akan menghasilkan suatu *output* dari jaringan yang telah di *input* atau bahkan akan menjadi *input*-an bagi *neuron* yang lain.

2.5.3 Arsitektur *Artificial Neural Network*

Net architecture atau susunan *neuron* dan pola keterkaitan antar *layer* dikategorikan sebagai *single layer*, *multilayer* dan *competitive layer* (Fausett, 1944). Banyaknya *layer* yang terdapat dalam *artificial neural network* menunjukkan banyaknya nilai bobot yang berhubungan dengan *layer* tersebut. Karena itu, nilai bobot adalah hal yang penting dalam jaringan syaraf tiruan.

a. *Single layer network*


Single layer net mempunyai satu *layer* untuk menghubungkan nilai bobotnya. *Neuron input* berhubungan langsung dengan *neuron output*. Jaringan ini menerima informasi dan memprosesnya secara langsung menjadi *output* tanpa melalui *hidden layer*. Ciri-ciri dari *single layer net* ini hanya mempunyai satu *layer input* dan satu *layer output*.



Gambar 3. Struktur *Single Layer Network*. (Sumber: Haykin, S., 2009)

b. *Multilayer Network*


Multilayer net adalah jaringan dengan tambahan satu *layer* atau lebih (*hidden neuron*) diantara *layer input* dan *output*. Jaringan dengan banyak *layer* ini dapat memecahkan masalah yang lebih rumit dibandingkan jaringan dengan satu *layer*.



Gambar 4. Struktur *Multi Layer Network*. (Sumber: Haykin, S., 2009)

c. *Competitive layer net*

Competitive layer net terdiri dari dua atau lebih jaringan syaraf tiruan. Arsitektur jaringan ini bisa menghubungkan satu *neuron* dengan *neuron* lainnya dan memiliki pengaturan bobot yang telah ditentukan serta tidak memiliki proses pelatihan. Pada lapisan ini, jaringan memiliki setidaknya satu *feedback loop* yang terdiri dari setiap *neuron* untuk memberikan kembali outputnya sebagai *input* pada *neuron* lain. Nilai bobot untuk setiap *neuron* adalah 1 dan bobot acak negatif dengan bobot *neuron* lainnya $-\eta$.



Gambar 5. Struktur *Competitive Layer Network*. (Sumber: Haykin, S., 2009)

2.6 *Artificial Neural Network* dengan Algoritma *Backpropagation*

Hinton dkk pada tahun 1986 yang pertama kali memperkenalkan *artificial neural network* atau jaringan syaraf tiruan dengan algoritma *backpropagation* yang kemudian dikembangkan oleh Rumelhart dan Mc Clelland pada tahun 1988. Umumnya jaringan syaraf tiruan menggunakan algoritma *backpropagation* didrancang untuk dioperasikan dalam metode pembelajaran terawasi (*supervised learning*) dengan setidaknya banyak lapisan (*multi layer network*) yang terdiri dari *input layer*, *hidden layer*, dan *output layer*.

Siang (2005) menyatakan bahwa pelatihan *backpropagation* meliputi 3 fase yaitu sebagai berikut:

1. Propagasi maju (*feedforward*)

Pola masukan dihitung maju mulai dari lapisan masukan hingga lapisan keluaran menggunakan fungsi aktivasi yang ditentukan.


2. Propagasi mundur/eror (*backpropagation of error*)

Perbedaan antara keluaran jaringan dengan target yang diinginkan adalah kesalahan yang terjadi. Kesalahan yang terjadi itu dipropagasi mundur. Dimulai dengan garis yang berhubungan langsung dengan unit di lapisan *output*.

3. Modifikasi bobot serta bias (*adjustment*)

Fausett (1994) mengemukakan pendapat bahwa *backpropagation* bekerja dengan terlebih dahulu mencari eror *output* dengan arah maju (*forward*) untuk mengoreksi bobot yang kemudian dilakukan dengan arah mundur (*backward*). Pada saat melakukan forward akan ada fungsi aktivasi yang akan mengaktifkan neuron-neuron untuk menghasilkan *output*. Fungsi aktivasi yang digunakan pada *backpropagation* umumnya kontinu, terdiferensial, dan tidak turun seperti halnya fungsi aktivasi *sigmoid*.

Adapun arsitektur jaringan syaraf tiruan dengan algoritma *backpropagation* adalah sebagai berikut.



Gambar 6. Arsitektur Artificial Neural Network Backpropagation. (Sumber: Fausett, 1994)

Berikut adalah persamaan *backpropagation*:

$$y = \sum_{k=1}^m \psi_o (w_{0k} + \sum_{j=1}^p w_{jk} \psi_h (v_{0j} + \sum_{i=1}^n v_{ij} x_i)) \quad (2.1)$$

dimana:

x_i = *input* jaringan ke-*i*

v_{0j} = bobot bias pada lapisan *input* ke lapisan tersembunyi ke-*j*

w_{0k} = bobot bias pada lapisan tersembunyi ke lapisan *output*

v_{ij} = bobot pada lapisan *input* ke- *i* ke lapisan tersembunyi ke-*j*

w_{jk} = bobot pada lapisan tersembunyi ke-*j* ke lapisan *output*

ψ_o = fungsi aktivasi yang digunakan pada lapisan tersembunyi

ψ_h = fungsi aktivasi yang digunakan pada lapisan *output*

2.7 Membangun Model *Artificial Neural Network*


2.7.1 *Hidden dan Nodes Layer*

Heaton (2008) berpendapat bahwa jumlah *hidden layer* yang digunakan akan berpengaruh terhadap perubahan hasil dari pelatihan. Jumlah *neuron* yang terlalu sedikit akan menghasilkan *output* yang kurang baik, sedangkan apabila *neuron* terlalu banyak akan memperlambat proses pelatihan dan mungkin akan terjadi pelatihan yang tak hingga. Banyak cara penentuan jumlah *hidden layer* yang tepat, berikut beberapa aturan yang sering dipakai:

1. Jumlah *hidden layer* lebih besar dari jumlah *neuron input* atau jumlah *output*.
2. Jumlah *hidden layer* seharusnya 2/3 besar dari jumlah *neuron input* ditambah jumlah *output*.
3. Jumlah *hidden layer* harus lebih kecil atau sama dengan dua kali jumlah *input layer*.

2.7.2 Dropout

(Strivastava dkk, 2014) *Dropout* adalah metode sederhana yang digunakan untuk mengatasi terjadinya *overfitting*. Teknik yang digunakan adalah regulasi *neural network* dimana *dropout* tidak memodifikasi *loss function*, tetapi memodifikasi jaringan *neural network* dengan cara sementara memutus *neuron* dari suatu *layer* dengan *probability (rate)* tertentu pada saat pelatihan.



Gambar 7. Perbandingan *neural network* tanpa *dropout* dan setelah menggunakan *dropout*. (Sumber: Strivastava dkk, 2014)

Pemutusan *neuron* secara acak pada jaringan akan membuat lapisan yang diputus memperbaiki kesalahan sebelumnya agar kinerja model menjadi optimal atau mengurangi *overfitting*. *Dropout* yang digunakan untuk menghasilkan model yang optimal umumnya 0.2 hingga 0.5, artinya sejumlah 20% hingga 50% *neuron* diputus secara acak pada jaringan. Namun, pemutusan *neuron* yang terlalu banyak akan mengakibatkan ketidak seimbangan pada jaringan dan tidak tercapainya *output* yang diinginkan.

2.7.3 *Epoch dan Batch Size*

Vijayalakshmi dan Venkatachalapathy (2019) mendefinisikan *epoch* adalah jumlah iterasi selama proses pelatihan yang memberikan *input* dari jaringan dan juga memperbarui bobot jaringan. Proses pelatihan berlangsung pada jaringan syaraf tiruan ke awal lagi. Dalam proses pelatihan, satu *epoch* memang membutuhkan waktu yang lama. Oleh karena itu, untuk mempercepat proses pelatihan dilakukan pembagian *per batch* yang disebut dengan *batch size*. Ukuran *batch* adalah istilah yang digunakan dalam pembelajaran mesin dan mengacu pada jumlah contoh pelatihan yang digunakan dalam satu iterasi dan merupakan salah satu *hyperparameter* terpenting yang sesuai dengan sistem pembelajaran mendalam. (Rochmawati dkk, 2021). Nilai yang biasa digunakan antara lain adalah 16, 32, 64 dengan mempertimbangkan angka kelipatan 2 yang dapat memudahkan proses pembagian *dataset* dalam pelatihan model.

2.7.4 Fungsi Aktivasi

Fungsi aktivasi adalah suatu fungsi yang akan mentransformasikan *input* menjadi *output* tertentu. Informasi diterima melalui *input* akan diproses melalui suatu fungsi perambatan. Fungsi aktivasi pada jaringan *backpropagation* memiliki beberapa karakteristik penting, kontinu, dan dapat dibedakan, serta tidak meningkat secara monoton. Demi meningkatkan efisiensi komputasi, diharapkan turunan dari fungsi tersebut mudah untuk dikomputasikan. Fungsi ini diharapkan memenuhi pendekatan nilai maksimum dan nilai minimum. (Puspitaningrum, 2006).


a. *Rectified Linear Unit (ReLU)*

ReLU merupakan fungsi aktivasi yang digunakan untuk menormalisasikan nilai yang dihasilkan *layer*. Persamaan pada fungsi aktivasi ini yaitu:

$$f(x) = \max(0, x) \quad (2.2)$$

Setiap *input* negatif yang diberikan akan selalu dipetakan menjadi 0 dan setiap *input* positif akan dipertahankan nilainya, sehingga tidak terdapat hasil yang bernilai negatif.

Adapun grafik fungsi aktivasi *ReLU* sebagai berikut:




Gambar 8. Fungsi Aktivasi *ReLU*. (Sumber : Maysanjaya, 2020)

b. *Sigmoid*

Fungsi *sigmoid* merupakan fungsi aktivasi yang sering digunakan pada *neural network* dengan algoritma *backpropagation*. Fungsi ini mengambil kisaran antara 0 sampai 1. Bentuk dari fungsi sigmoid yaitu:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.3)$$

Adapun grafik fungsi aktivasi *Sigmoid* sebagai berikut:




Gambar 9. Fungsi aktivasi *Sigmoid*. (Sumber : Maysanjaya, 2020)

c. *TanH*

Fungsi aktivasi alternatif untuk *sigmoid* adalah fungsi aktivasi *tanh*. Seperti fungsi *sigmoid*, fungsi *tanh* berbentuk “S”, tetapi fungsi ini menghasilkan nilai antara -1 dan 1. Oleh karena itu, fungsi *tanh* mirip dengan fungsi *sigmoid*, tetapi rentang nilai yang luas membuatnya efektif untuk pemodelan nonlinear yang kompleks. Bentuk dari fungsi *tanh* adalah:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

Adapun grafik fungsi aktivasi *TanH* sebagai berikut:



Gambar 10. Fungsi aktivasi *TanH*. (Sumber : Maysanjaya, 2020)

2.7.5 *Hyperparameter Optimizer*

Hyperparameter adalah parameter yang terdapat pada model *neural network* yang telah ditentukan diawal dan tidak berubah selama proses pelatihan (Michelucci, 2018).

Hyperparameter yang umum digunakan pada *neural network* adalah:

1. Jumlah *Hidden Layer* dan *Nodes*.
2. *Dropout*.
3. *Epoch* dan *Batch Size*.
4. Fungsi Aktivasi.
5. dan lain sebagainya.

Menemukan model *neural network* terbaik diperlukan kombinasi parameter yang optimal. Mencari kombinasi yang optimal akan menghabiskan waktu yang cukup lama karena harus melakukan pelatihan pada setiap kombinasi, dengan demikian diperlukan metode untuk mendapatkan kombinasi yang optimal dengan sedikit mungkin jumlah pelatihan untuk mempersingkat waktu. *Hyperparameter tuning* atau *hypertuning* menggunakan *early stopping* agar proses pembelajaran yang dilakukan model berhenti ketika kondisi telah terpenuhi (Li dkk, 2018).

2.8 Validasi Model

Hanke dan Wichern (2014) menyatakan bahwa teknik prediksi yang menggunakan data kuantitatif dengan data *time series* tertentu, terdapat kesalahan/eror yang dihasilkan oleh teknik tersebut. Oleh karena itu, diperlukan suatu metode untuk mengukur seberapa besar kesalahan yang dapat dihasilkan oleh metode prediksi untuk dipertimbangkan kembali sebelum mengambil keputusan. Metode yang dapat digunakan untuk mengevaluasi kesalahan dalam teknik prediksi adalah *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), *Mean Absolute Presentase Error* (MAPE).

a. *Mean Squared Error* (MSE)

Mean Square Error mengukur kuadrat rata-rata kesalahan antara target yang diamati dan nilai prediksi. Semakin kecil MSE, semakin baik hasil prediksinya.

$$MSE = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2 \quad (2.5)$$

dengan:

y_t = nilai aktual pada periode t

\hat{y}_t = nilai prediksi pada periode t

n = jumlah periode prediksi

b. *Root Mean Square Error* (RMSE)

Mean Square Error diukur dalam satuan kuadrat, *Root Mean Square Error* dapat ditafsirkan sebagai jarak rata-rata, antara nilai yang diprediksi dan diamati, diukur dalam satuan variabel target.

$$RMSE = \sqrt{MSE} \quad (2.6)$$

c. *Mean Absolute Presentase Error* (MAPE)

Mean Absolute Presentase Error menghitung kesalahan menggunakan kesalahan absolut pada tiap periode yang dibagi dengan nilai observasi yang nyata untuk periode tersebut. Kemudian, merata-rata kesalahan presentase absolut tersebut. *Mean Absolute Presentase Error* dapat dihitung menggunakan rumus berikut:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \times 100\% \quad (2.7)$$

dengan:

n : Jumlah Sampel

y_t : Nilai Aktual Indeks pada Periode ke- t

\hat{y}_t : Nilai Prediksi Indeks pada Periode ke- t

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Penelitian ini dilakukan pada semester genap tahun akademik 2021/2022 di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan adalah data sekunder yang diperoleh dari <https://www.bi.go.id/id/statistik/informasi-kurs/transaksi-bi/> mengenai data nilai tukar mata uang Rupiah Indonesia (Rp) dengan Euro Eropa (€) selama 18 bulan yang dihitung sejak Januari 2020 hingga Juni 2021 dalam frekuensi data harian tanpa memasukkan akhir pekan dan hari libur nasional dengan jumlah 377 data. Berikut adalah data penelitian yang digunakan:

Tabel 1. Data Kurs Jual dan Kurs Beli Rupiah terhadap Euro

Tanggal	Kurs Jual	Kurs Beli
02/01/2020	15672,34	15510,86
03/01/2020	15615,39	15454,48
06/01/2020	15666,80	15509,52
07/01/2020	15658,84	15497,49
08/01/2020	15621,09	15464,27

...
24/06/2021	17338,56	17160,28
25/06/2021	17335,07	17161,14
28/06/2021	17341,78	17166,35
29/06/2021	17370,33	17194,61
30/06/2021	17343,78	17165,43

3.3 Metode Penelitian

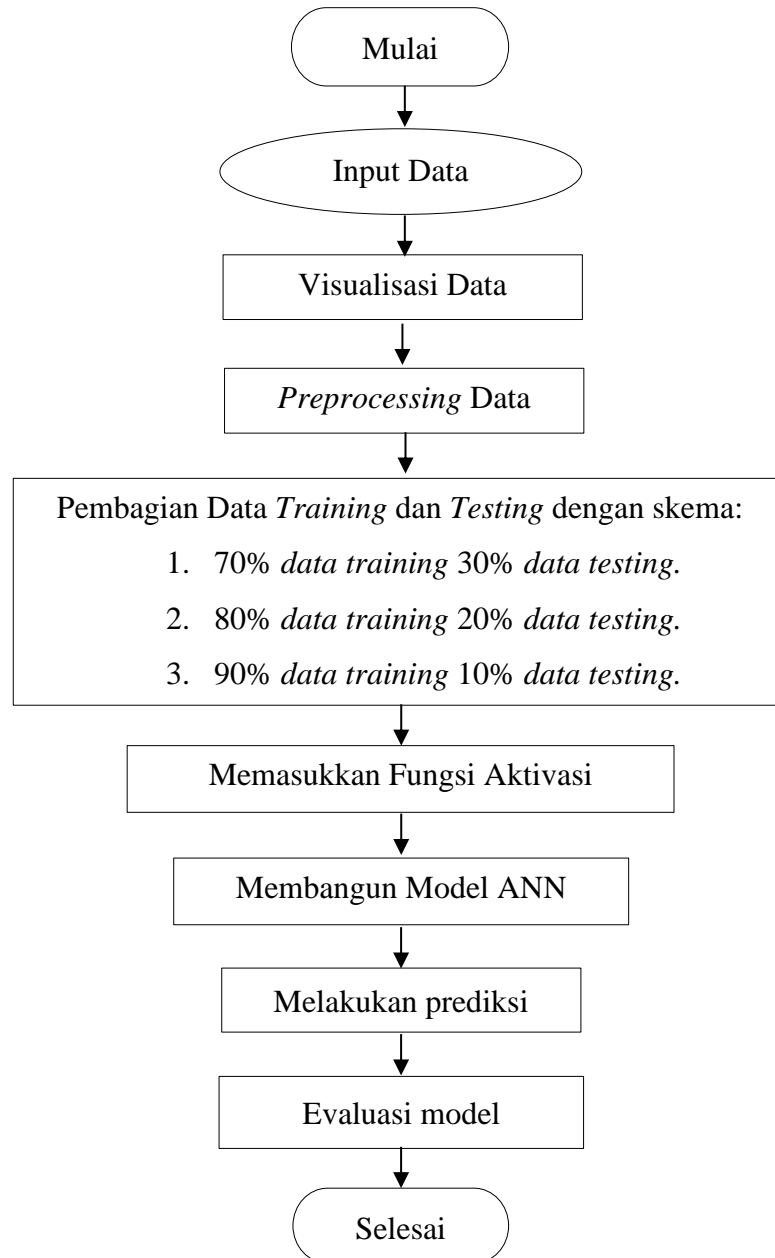
Penelitian ini akan membangun model ANN untuk memprediksi nilai tukar mata uang Rupiah Indonesia (Rp) dengan Euro Eropa (€) menggunakan algoritma *backpropagation* dengan bantuan *software python* yang didukung oleh Google Colab. Setelah itu akan dievaluasi berdasarkan nilai *error* terkecil dari fungsi aktivasi yang digunakan.

Adapun Langkah-langkah penelitian ini yaitu:

1. Mengumpulkan data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro yang diperoleh dari <https://www.bi.go.id/id/statistik/informasi-kurs/transaksi-bi/> ke dalam Excel.
2. Penginputan data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro ke dalam *software python*.
3. Melakukan visualisasi data dengan melihat plot sebaran pada data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro.
4. Melakukan *preprocessing* data:
 - Mengecek apakah ada data hilang pada data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro,
 - Mengecek apakah ada *outlier* atau pencilan data pada data Nilai Kurs Jual dan Kurs Beli Rupiah terhadap Euro menggunakan *boxplot*,
 - Melakukan *Data Slicing* atau penentuan *variable*,
 - Melakukan *Data Scaling* atau normalisasi data menggunakan *StandardScaler* berdasarkan variabel yang sudah ditentukan,

5. Pembagian *data training* dan *data testing* pada setiap variable dengan skema:
 - 70% *data training* 30% *data testing*,
 - 80% *data training* 20% *data testing*,
 - 90% *data training* 10% *data testing*.
6. Mengaktifkan neuron menggunakan fungsi aktivasi:
 - *Sigmoid*,
 - *ReLU*,
 - *TanH*.
7. Membangun model *Artificial Neural Network* dengan penentuan parameter terbaik berdasarkan jumlah *nodes* pada *hidden layer*, *dropout*, *batch size*, *epoch* menggunakan *hypertuning*.
8. Melakukan prediksi menggunakan parameter terbaik serta perbandingan nilai hasil prediksi terhadap data actual.
9. Evaluasi model prediksi dengan melihat nilai RMSE dan MAPE yang diperoleh.

Secara singkat alur *artificial neural network* menggunakan *software python* sebagai berikut:



V. KESIMPULAN

Bedasarkan hasil penelitian, berikut ini merupakan beberapa kesimpulan yang dapat diambil.

1. Model *Artificial Neural Network* yang telah didapat dengan skema 90% *training data* dan 10% *testing data* untuk memprediksi nilai Kurs Jual Rupiah terhadap Euro dan telah melalui uji coba beberapa parameter, didapatkan bahwa model *artificial neural network* Kurs Jual Rupiah terhadap Euro memiliki *input layer* dengan 10 *nodes*, 2 *hidden layers* dengan 19 *nodes* dan 13 *nodes*, *output layer*, *dropout* sebesar 0.2, *batch size* sebesar 32, *epoch* sebesar 100, dan fungsi aktivasi *TanH*.
2. Model *Artificial Neural Network* yang telah didapat dengan skema 90% *training data* dan 10% *testing data* untuk memprediksi nilai Kurs Beli Rupiah terhadap Euro dan telah melalui uji coba beberapa parameter, didapatkan bahwa model *artificial neural network* Kurs Beli Rupiah terhadap Euro memiliki *input layer* dengan 10 *nodes*, 2 *hidden layers* dengan 19 *nodes* dan 13 *nodes*, *output layer*, *dropout* sebesar 0.2, *batch size* sebesar 32, *epoch* sebesar 100, dan fungsi aktivasi *TanH*.
3. Model *Artificial Neural Network* yang diterapkan untuk melakukan peramalan nilai Kurs Jual Rupiah terhadap Euro memiliki MSE 0.083, MAPE 0.0059%, serta akurasi 99,994% dengan mengadakan data akhir pekan dan hari libur nasional, atau data dalam frekuensi harian.
4. Model *Artificial Neural Network* yang diterapkan untuk melakukan peramalan nilai Kurs Beli Rupiah terhadap Euro memiliki MSE 0.075, MAPE 0.0053%, serta akurasi 99,994% dengan mengadakan data akhir pekan dan hari libur nasional, atau data dalam frekuensi harian.

DAFTAR PUSTAKA

- Baxter, Marianne dan Stockman, Alan C. 1989. *Buusiness cycles the exchange-rate regime: Some international evidence*. *Journal of Monetary Economics*. **23**(3):377-400.
- Elarabi, H. 2014. Comparison of Different Methods of Application of Neural Network on Soil Profile of Khartoum State. *International Journal of Science, Technology and Society*. **2**(3): 59.
- Fausett, L. 1994. *Fundamentals of Neural Networks: Achitectures, Algorithms, and Applications*. Prentice Hall. New Jersey.
- Hamid, N. A., Nawi, N. M., Ghazali, R., dan Salleh, M. N. M. 2011. Accelerating Learning Performance of Backpropagation Algorithm by Using Adaptive Gain Together with Adaptive Momentum and Adaptive Learning Rate on Classification Problems. *International Journal Software*. **5**(4): 31–44.
- Hanke, J.E., dan Wichern, D. 2014. *Business Forecasting*. 9th Edition. Pearson, USA
- Haykin. S. 2009. *Neural Networks and Learning Machines*. Pearson. USA
- Heaton, J. 2008. *Introduction to Neural Network for Java*. 2nd Ed. Heaton Research Inc. Florida.
- Hendikawati, P. 2014. *Algoritma Levenberg-Marquardt Untuk Training Feedforward NeuralNetwork Pada Prediksi Data Time Series*. Jurusan Matematika FMIPA UGM. Yogyakarta.
- Hinton, G. E., dan Willliams, R. J. 1986. *Learning representations by back-propagating errors*. University of California. California.

- Kafil, M. 2019. Penerapan Metode K-Nearest Neighbors untuk Memprediksi Penjualan Berbasis Web pada Boutiq Dealove Bondowoso. *Jurnal Mahasiswa Teknik Informatika*. 3(2): 60-61.
- Khasei, M., dan Bijari, M. 2010. *An Artificial Neural Network (p,d,q) Model for Timeseries Forecasting*. Department of Industrial Engineering, Isfahan University of Technology. Iran.
- Kusumadewi, S. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu. Yogyakarta.
- Li, Lisha, K. Jamieson, A. Rostamizadeh, A. Talwalkar. 2018. Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *Journal of Machine Learning Research*. 18(185): 12-15.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Prediksi*. Ed. Ke-2. Terjemah Untung Sus Andriyanto. Erlangga, Jakarta.
- Maysanjaya, D.M.I. 2020. Klasifikasi Pneumonia Pada Citra X-rays Paru-paru dengan *Convolutional Neural Network*. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*. 9(2):190-195.
- Michelucci, U. 2018. *Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Network*. Apress Berkeley. California.
- Puspitaningrum, D. 2006. *Pengantar Jaringan Syaraf Tiruan*. Andi. Yogyakarta.
- Ripley, B. D. 1996. *Pattern Recognition and Neural Network*. Cambridge University Press.
- Rochmawati, N., Hidayati, H.B., Yamasari, Y., Tjahyaningtjas, H.P.A., Yustanti, W., dan Prihanto, A. 2021. Analisa *Learning Rate* dan *Batch size* Pada Klasifikasi Covid Menggunakan *Deep learning* dengan *Optimizer Adam*. *Journal Information Engineering and Educational Technology*. 5(2):44-48.
- Rumelhart, D. E., dan McClelland, J. L. 1988. *Explorations in parallel distributed processing: A handbook of models, programs, and exercises*. The MIT Press. Massachusetts.
- Schuerer, K dan Maufrais, C. 2010. *Introduction to Programming using Python*. Pearson. Boston, Massachusetts.

- Sembiring, F dan Erfina, A. 2020. *Bahasa Ular untuk Pemrograman Python*. Insan Cendekia Mandiri. Solok, Sumatera Barat.
- Siang, J. J. 2009. *Jaringan Syaraf Tiruan dan Pemograman Menggunakan Matlab*. Yogyakarta. Andi.
- Strivastava. N, Hinton. G, Krizhevsky. A, Sutskever, dan Salakhutdinov. R. 2014. Dropout: A Simple Way to Prevent Neural Networks Overfitting. *Journal of Machine Learning Research*. **15**(56): 1929-1934.
- Vijayalakshmi, V dan Venkatachalapathy, K. 2019. *Deep Neural Network for Multi-Class Prediction of Student Performance in Educational Data*. *International Journal of Recent Technology and Engineering (IJRTE)*. **8**(2): 5073-5081.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd ed. Pearson Education Hall. New Jersey.
- World Health Organization. WHO coronavirus disease (COVID-19) dashboard. [https://covid19.who.int/\(2020\)](https://covid19.who.int/(2020))
- Yu, Lean, Souyang Wang, dan Kin Keung Lai. 2007. *Foreign Exchange Rate Forecassting with Artificial Neural Network*. New York.