

**PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* UNTUK
MEMPREDIKSI INFLASI DI INDONESIA**

(Skripsi)

Oleh

**ELSA SAVENIA KILI KILI
1817031096**



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

ABSTRACT

APPLICATION OF ARTIFICIAL NEURAL NETWORK METHOD TO PREDICT INFLATION IN INDONESIA

By

Elsa Savenia Kili Kili

A country's economy can be seen from various macroeconomic indicators, one of which is inflation. The inflation rate of a country, which tends to be low and stable, is considered to be in good condition, so it is important to keep the inflation rate stable and under control. This study will predict the inflation rate in Indonesia using the Artificial Neural Network (ANN) method using Indonesia's Inflation data. Indonesia's inflation data pattern displays non-stationary data due to seasonal fluctuations. After the first differencing, the data is stationary and will utilize one data lag (lag $k=1$). Prediction of the inflation rate in Indonesia will be done using the Artificial Neural Network (ANN) method with backpropagation algorithm using data lag $k = 1$ to determine the best network structure that has a minimum error value. Hyperparameter Tuning testing produces the smallest loss value, which is 0.027254, and the best number of dropouts, epochs, and batch sizes are obtained, namely dropouts of 0.2, epochs of 50, and batch size of 16. The evaluation model used is Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and Accuracy. The RMSE, MAPE, and Accuracy values are 0.0424 , 0.1611% , and 99.8388%, respectively. The prediction results that have been obtained will be used to determine the forecast for the next nine months.

Keywords: Inflation, Artificial Neural Network, Backpropagation, Data Mining, Prediction

ABSTRAK

PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* UNTUK MEMPREDIKSI INFLASI DI INDONESIA

Oleh

Elsa Savenia Kili Kili

Perekonomian suatu negara dapat dilihat dari berbagai indikator makro ekonomi, salah satunya adalah inflasi. Laju inflasi suatu negara yang cenderung rendah dan stabil, dianggap perekonomiannya dalam kondisi yang baik. Dengan begitu, penting untuk menjaga nilai inflasi tetap stabil serta terkendali. Dalam penelitian ini akan dilakukan prediksi tingkat inflasi di Indonesia menggunakan metode Artificial Neural Network (ANN) dengan menggunakan Pola data inflasi Indonesia menampilkan data yang tidak stasioner akibat fluktuasi musiman. Setelah differencing pertama, data stasioner dan akan memanfaatkan satu data lag (lag k=1). Prediksi tingkat inflasi di Indonesia akan dilakukan dengan menggunakan metode Artificial Neural Network (ANN) dengan algoritma backpropagation menggunakan data lag k=1 untuk menentukan struktur jaringan terbaik yang memiliki nilai error minimum. Pengujian Hyperparameter Tuning menghasilkan nilai loss terkecil, yaitu 0.027254 dan didapatkan jumlah dropout, epoch dan batch size terbaik, yaitu dropout sebesar 0.2, epoch sebesar 50, dan batch size sebesar 16. Evaluasi model yang digunakan adalah Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Akurasi. Nilai RMSE, MAPE, dan Akurasi secara berturut-turut, yaitu 0,0424 , 0,1611% , dan 99,8388%. Hasil prediksi yang telah diperoleh akan digunakan untuk menentukan peramalan selama sembilan bulan ke depan.

Kata kunci: Inflasi, *Artificial Neural Network*, *Backpropagation*, *Data Mining*, Prediksi.

**PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* UNTUK
MEMPREDIKSI INFLASI DI INDONESIA**

Oleh

Elsa Savenia Kili Kili

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* UNTUK MEMPREDIKSI INFLASI DI INDONESIA**

Nama Mahasiswa : **Elsa Savenia Kili Kili**

Nomor Pokok Mahasiswa : **1817031096**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



MENYETUJUI

1. Komisi Pembimbing

Drs. Nusyirwan, M.Si.
NIP. 196610101992051001

Dr. Muslim Ansori, S.Si., M.Si.
NIP. 197202271998021001

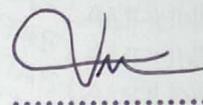
2. Ketua Jurusan Matematika

Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

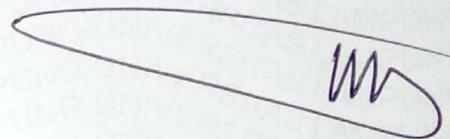
1. Tim Penguji

Ketua : Drs. Nusyirwan, M.Si.



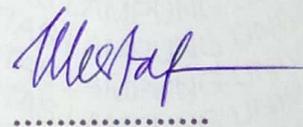
.....

Sekretaris : Dr. Muslim Ansori, S.Si., M.Si.



.....

Penguji
Bukan Pembimbing : Prof. Drs. Mustofa Usman, M.A., Ph.D.



.....

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Sripto Dwi Yuwono, S.Si., M.T.
NIP. 197407052000031001

Tanggal Lulus Ujian Skripsi : 4 Agustus 2022

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : **Elsa Savenia Kili Kili**

Nomor Pokok Mahasiswa : **1817031096**

Jurusan : **Matematika**

Judul Skripsi : **PENERAPAN METODE *ARTIFICIAL NEURAL NETWORK* UNTUK
MEMPREDIKSI INFLASI DI INDONESIA**

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, Agustus 2022
Penulis



Elsa Savenia Kili Kili

RIWAYAT HIDUP

Penulis bernama Elsa Savenia Kili Kili dilahirkan di Kota Bandar Lampung, Provinsi Lampung pada 11 November 2000. Penulis merupakan anak kedua dari dua bersaudara pasangan Bapak Gamaliel Beben dan Ibu Sopiya.

Penulis pertama kali menempuh pendidikannya di Taman Kanak-Kanak Puri Mandiri Bandar Lampung pada tahun 2006/2007 dan melanjutkan pendidikannya ke Sekolah Dasar di SDN 1 Sukabumi Indah pada tahun 2007-2013. Kemudian, penulis melanjutkan jenjang pendidikannya di SMPN 29 Bandar Lampung pada tahun 2013-2016. Jenjang pendidikan selanjutnya di SMAN 9 Bandar Lampung pada tahun 2016-2018.

Pada tahun 2018 penulis diterima sebagai mahasiswa S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN) pada pilihan ke-3. Pada tahun 2020 penulis melakukan Kuliah Praktik (KP) di Badan Kependudukan dan Keluarga Berencana Nasional (BKKBN) Provinsi Lampung. Pada tahun 2021 penulis melakukan Kuliah Kerja Nyata (KKN) di Perumahan Bukit Sukabumi Indah, Sukabumi, Bandar Lampung. Pada tahun 2021 penulis mengikuti kegiatan MBKM Studi Independen di PT Microsoft Indonesia pada *learning track Microsoft Productivity : The Modern Workplace*. Dilanjutkan pada tahun 2022 penulis mengikuti Kembali kegiatan MBKM Studi Independen di PT Microsoft Indonesia x PT MariBelajar Indonesia Cerdas pada *learning track Intelligence Cloud*.

KATA INSPIRASI

*Permulaan hikmat adalah takut akan Tuhan, dan mengenal Yang Mahakudus
adalah pengertian.*

(Amsal 9:10)

*Dan orang-orang bijaksana akan bercahaya seperti cahaya cakrawala, dan yang
telah menuntun banyak orang kepada kebenaran seperti bintang-bintang, tetap
untuk selama-lamanya.*

(Daniel 12:3)

*Segala perkara dapat kutanggung di dalam Dia yang memberi kekuatan
kepadaku.*

(Filipi 4:13)

You are much stronger than you think.

(penulis)

PERSEMBAHAN

Bersukacitalah senantiasa. Tetaplah berdoa. Mengucap syukurlah dalam segala hal, sebab itulah yang dikehendaki Allah di dalam Kristus Yesus bagi kamu.
(1 Tesalonika 5:16-18)

Terimakasih Tuhan Yesus Kristus untuk segala berkat dan penyertaan yang Engkau berikan kepada anak-Mu ini, sehingga mampu menyelesaikan Skripsi ini.
Dengan penuh ketulusan karya sederhana ini saya persembahkan untuk :

Bapak Gamaliel Bebena dan Mama Sopiya

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

Kakak Stefanus Kili Kili

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

Dosen Pembimbing dan Pembahas

Terima kasih kepada bapak 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 Tuhan YME karena berkat segala rahmat dan karunia-Nya penulis dapat menyelesaikan skripsi dengan judul “Penerapan Metode *Artificial Neural Network* untuk Memprediksi Inflasi di Indonesia”.

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

1. Bapak Drs. Nusyirwan, M.Si., Bapak Dr. Muslim Ansori, S.Si., M.Si., dan Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D. selaku Dosen Pembimbing I, Dosen Pembimbing II, dan Dosen Penguji yang telah bersedia membimbing, memberikan bantuan, motivasi, arahan, kritik, serta saran dalam menyelesaikan skripsi ini.
2. Ibu Prof. Dra. Wamiliana, M.A., Ph.D. selaku dosen Pembimbing Akademik.
3. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika.
4. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Seluruh dosen, staff, karyawan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Mama, Bapak, Kakak, dan keluarga besarku tercinta atas kasih sayang, perhatian, dan dukungan baik doa maupun materiil serta memberi motivasi sehingga penulisan skripsi ini dapat terselesaikan.
7. Sahabat-sahabat seperjuanganku Tri Acil Mutu, Mupeng Bacol, Markisut, Repisang, Ipeh, Eja, dan A(n)jeng yang memberi dukungan selama ini.

8. Riris, Kintan, Aulia Putri, dan Ria yang telah memberikan dukungan, bantuan, serta menemani penulis selama menyusun skripsi ini.
9. Semua pihak yang telah membantu dalam menyelesaikan skripsi ini yang tidak bisa penulis sebutkan satu persatu.

Penulis menyadari masih banyak kekurangan dalam skripsi 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, Agustus 2022
Penulis,

Elsa Savenia Kili Kili

DAFTAR ISI

	Halaman
DAFTAR ISI	ii
DAFTAR TABEL	iv
DAFTAR GAMBAR	v
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	3
1.3 Manfaat Penelitian.....	3
II. TINJAUAN PUSTAKA	4
2.1 Prediksi.....	4
2.2 Data Deret Waktu (<i>Time series</i>).....	4
2.2.1 Definisi Deret Waktu (<i>Time series</i>).....	4
2.2.2 Model Data Deret Waktu ARIMA	5
2.3 <i>Data Mining</i>	8
2.4 <i>Machine Learning</i>	9
2.5 <i>Artificial Neural Network (ANN)</i>	10
2.5.1 Pengertian <i>Artificial Neural Network (ANN)</i>	10
2.5.2 Komponen-Komponen <i>Artificial Neural Network (ANN)</i>	13
2.5.3 Arsitektur <i>Artificial Neural Network (ANN)</i>	14
2.6 <i>Artificial Neural Network</i> dengan Algoritma <i>Backpropagation</i>	15
2.7 Parameter <i>Artificial Neural Network (ANN)</i>	17
2.7.1 <i>Hyperparameter Optimizer</i>	17
2.7.2 <i>Hidden Layer</i>	17
2.7.3 <i>Dropout</i>	18
2.7.4 <i>Epoch dan Batch Size</i>	19
2.7.5 Fungsi Aktivasi.....	19
2.7.6 <i>Weight (W)</i>	21
2.7.7 <i>Bias (θ)</i>	21
2.8 Validasi Model	21
2.9 Inflasi.....	23

III. METODOLOGI PENELITIAN	24
3.1 Waktu dan Tempat	24
3.2 Data Penelitian	24
3.3 Metode Penelitian.....	24
IV. HASIL DAN PEMBAHASAN	27
4.1 Pengumpulan Data	27
4.2 Gambaran Umum Data.....	28
4.3 <i>Input Data</i>	28
4.4 <i>Praproses Data</i>	29
4.4.1 <i>Missing Value</i>	30
4.4.2 Pola Data Inflasi Indonesia.....	30
4.4.3 Penstasioneran Data Inflasi Indonesia.....	31
4.4.4 <i>Scaling Data</i>	34
4.4.5 Pembagian <i>Training Data</i> dan <i>Testing Data</i>	35
4.5 Membangun Arsitektur <i>Artificial Neural Network (ANN)</i> menggunakan Algoritma <i>Backpropagation</i>	36
4.5.1 Menentukan Nilai Parameter	36
4.6 Menguji Arsitektur ANN	37
4.7 Prediksi Inflasi di Indonesia.....	38
4.7.1 Denormalisasi Data	38
4.7.2 Hasil Prediksi Inflasi di Indonesia.....	38
4.8 Evaluasi Arsitektur <i>Artificial Neural Network (ANN)</i>	39
4.9 Peramalan Inflasi di Indonesia	40
V. KESIMPULAN	42
DAFTAR PUSTAKA	43
LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
Tabel 1. Data Inflasi di Indonesia	27
Tabel 2. Gambaran umum data Inflasi di Indonesia	28
Tabel 3. Data <i>Input</i>	29
Tabel 4. <i>Missing Value</i> pada data Inflasi di Indonesia.....	30
Tabel 5. Nilai Data <i>lag k=1</i>	33
Tabel 6. <i>Dataset</i> tanpa <i>missing</i> data.....	34
Tabel 7. Hasil Data <i>Scaling</i>	35
Tabel 8. Evaluasi Arsitektur ANN.....	40
Tabel 9. Hasil Peramalan Inflasi di Indonesia	41

DAFTAR GAMBAR

Gambar	Halaman
Gambar 1. Pola Data <i>Time series</i>	5
Gambar 2. <i>Artificial Neuron</i> sederhana	12
Gambar 3. <i>Neural Network</i> sederhana	12
Gambar 4. Struktur <i>Neuron Artificial Neural Network</i>	13
Gambar 5. Struktur <i>Single Layer, Multilayer, dan Competitive Layer Network</i> ...	14
Gambar 6. <i>Backpropagation neural network</i> dengan satu <i>hidden layer</i>	16
Gambar 7. <i>Neural network</i> tanpa <i>dropout</i> dan setelah menggunakan <i>dropout</i>	18
Gambar 8. Fungsi Aktivasi ReLU.....	20
Gambar 9. Fungsi aktivasi <i>Sigmoid</i>	20
Gambar 10. Grafik <i>time series</i> data Inflasi Indonesia.....	31
Gambar 11. Korelogram ACF dan PACF data deret waktu Inflasi Indonesia.....	31
Gambar 12. Grafik deret waktu setelah stasioner	32
Gambar 13. Korelogram ACF dan PACF setelah stasioner.....	33
Gambar 14. Arsitektur Jaringan Syaraf Tiruan	37
Gambar 15. Grafik <i>loss</i>	38
Gambar 16. Grafik prediksi	39
Gambar 17. Plot Gabungan Hasil Peramalan.....	41

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Banyak indikator ekonomi makro yang dapat digunakan untuk menentukan perekonomian suatu negara. Nilai tukar, ekspansi ekonomi, defisit neraca perdagangan, dan inflasi adalah beberapa indikator ekonomi makro. Salah satu dari sekian banyak indikator ekonomi makro, inflasi merupakan indikator yang penting untuk perekonomian suatu negara. Sejumlah tujuan kebijakan ekonomi makro, antara lain pertumbuhan ekonomi, prospek lapangan kerja, distribusi pendapatan, dan neraca pembayaran, dipengaruhi secara signifikan oleh inflasi. Selain itu, inflasi dapat menyebabkan krisis keuangan di negara mana pun (Martanto, dkk, 2021). Laju inflasi suatu negara yang cenderung rendah dan stabil, dianggap perekonomiannya dalam kondisi yang baik. Salah satu prasyarat pertumbuhan ekonomi yang baik dan juga berkesinambungan yaitu laju inflasi yang stabil. Kenaikan tingkat harga rata-rata barang dan jasa disebut sebagai inflasi (Mankiw, 2007). Inflasi memberikan dampak yang signifikan terhadap kesejahteraan masyarakat karena berdampak langsung pada kemampuan masyarakat untuk membeli sejumlah kebutuhan pokok. Oleh karena itu, sangat penting untuk menjaga tingkat inflasi yang konsisten dan terkendali.

Ilmu untuk memperkirakan peristiwa masa yang akan datang disebut dengan prediksi. Prediksi juga merupakan proses dalam menemukan pola dari data yang memanfaatkan berbagai faktor lain di masa depan. Tujuan dari tugas prediksi yaitu memprediksi nilai atribut tertentu berdasarkan nilai atribut lainnya. *Autoregressive Integrated Moving Average (ARIMA)* merupakan salah satu dari sekian banyak

metodologi data runtun waktu yang sering digunakan untuk peramalan. Metode ARIMA memiliki sejumlah prasyarat lainnya yang harus terpenuhi dan model ARIMA hanya dapat digunakan untuk data stasioner atau linier, dengan demikian metode *Artificial Neural Network* (ANN) akan digunakan dalam penelitian ini sebagai metode lain untuk memprediksi data deret waktu.

Saat melakukan prediksi penting untuk menggunakan metode yang sesuai untuk meminimalkan eror, metode *Artificial Neural Network* (ANN) biasanya digunakan untuk membuat prediksi dengan nilai akurasi tertinggi. Sistem pemrosesan informasi yang menyerupai jaringan saraf biologis disebut dengan *Artificial Neural Network* (Fausett, 1994). Salah satu algoritma *Artificial Neural Network* yang sering digunakan untuk mengatasi masalah peramalan adalah metode *backpropagation*. Hal ini dimungkinkan karena metode *backpropagation* adalah salah satu bentuk pendekatan pelatihan ANN terbimbing. Pola masukan dan pola yang diinginkan disajikan ke jaringan sebagai sepasang pola. Ketika suatu pola dimasukkan ke dalam jaringan, bobotnya disesuaikan untuk mengurangi perbedaan antara pola keluaran dan pola yang diinginkan. Proses *training* ini dilakukan berulang kali untuk memastikan bahwa pola yang diinginkan dipenuhi oleh setiap pola yang dikeluarkan oleh jaringan (Fausett, 1994). Saat memodelkan data yang kompleks, salah satu metode yang fleksibel dan akurat adalah metode ANN (Fausett, 1994).

Berdasarkan penelitian sebelumnya yang menunjukkan metode *Artificial Neural Network* (ANN) menghasilkan peramalan dengan tingkat eror yang rendah dalam studi kasus inflasi, oleh karena itu metode ANN dipilih. Penelitian Mega Silfiani dan Suhartono (2012) menjelaskan bahwa *Single ANN* memiliki *Root Mean Square Error* (RMSE) paling rendah jika dibandingkan dengan ARIMA, ARIMA Ensambel (ARIMAX), *Single ANN*, ANN Ensambel, dan ANN-ARIMA Ensemble untuk peramalan tingkat inflasi Indonesia. Selanjutnya temuan studi dari Emi Nakamura (2004) dengan judul "*Inflation Forecasting Using A Neural Network*" menunjukkan bahwa ANN memberikan performa yang buruk dalam meramalkan

kegiatan ekonomi makro dengan model linear. Namun pada peramalan inflasi, ANN memberikan performa yang baik pada model *Autoregressive* untuk peramalan dua sampai tiga kuartal ke depan. Oleh karena itu, penulis tertarik untuk melakukan penelitian dalam hal memprediksi tingkat inflasi di Indonesia menggunakan metode *Artificial Neural Network* (ANN) untuk dapat menghasilkan nilai akurasi tertinggi sehingga nilai prediksi memiliki nilai yang sesuai dengan nilai aktual.

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini yaitu :

1. Menentukan struktur jaringan terbaik untuk memprediksi inflasi di Indonesia.
2. Melakukan prediksi terhadap inflasi di Indonesia menggunakan metode *Artificial Neural Network* (ANN).
3. Mengetahui nilai akurasi untuk ketepatan metode *Artificial Neural Network* (ANN) pada data inflasi di Indonesia.

1.3 Manfaat Penelitian

Manfaat yang dapat diperoleh dari penelitian ini adalah :

1. Memberikan pengetahuan terkait metode *Artificial Neural Network* (ANN).
2. Sebagai bahan rujukan pengembangan ilmu matematika dalam memprediksi inflasi di Indonesia serta menjadi bahan pertimbangan dan memberikan informasi bagi peneliti yang akan melakukan penelitian tentang inflasi di Indonesia.
3. Mengetahui nilai prediksi inflasi di Indonesia menggunakan metode *Artificial Neural Network* (ANN).

II. TINJAUAN PUSTAKA

2.1 Prediksi

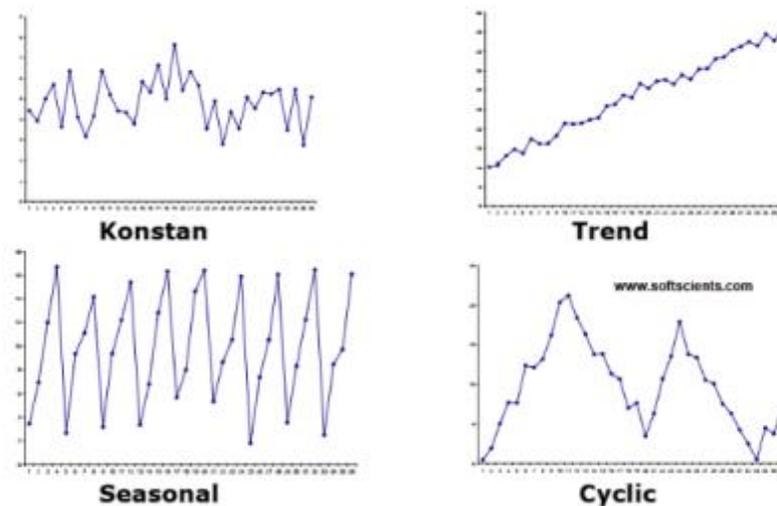
Herdianto (2013) menjelaskan bahwa prediksi adalah perkiraan sistematis tentang apa yang paling mungkin terjadi di masa depan berdasarkan informasi dari masa lalu dan masa kini, dengan tujuan meminimalkan eror (perbedaan antara apa yang sebenarnya terjadi dan hasil yang diharapkan). Prediksi tidak harus memberikan jawaban pasti tentang apa yang akan terjadi, melainkan bertujuan untuk mengidentifikasi solusi yang sedekat mungkin dengan apa yang mungkin terjadi. Prediksi bertujuan untuk mengidentifikasi pola sistematis serta menemukan pola hubungan tren berdasarkan data historis. Pengumpulan data historis di sini berperan sebagai tahap pertama yang dilakukan untuk prediksi atau peramalan. Pengumpulan data historis ini tidak representatif atau dapat dikatakan kurang akurat dan kurang memadai, sehingga akan sangat mempengaruhi ketidakakuratan data hasil prediksi. Semakin besar eror yang dihasilkan maka semakin tidak akurat hasil dari prediksi yang diperoleh.

2.2 Data Deret Waktu (*Time series*)

2.2.1 Definisi Deret Waktu (*Time series*)

Wei (2006) menjelaskan bahwa deret waktu adalah kumpulan data yang diperoleh melalui pengamatan tindakan yang dilakukan pada interval waktu yang teratur dan dicatat secara berurutan sesuai dengan urutan kejadian pada interval yang telah ditentukan. Deret waktu adalah metode statistik yang digunakan untuk meramalkan

struktur probabilistik situasi di masa depan dalam rangka pengambilan keputusan untuk strategi tertentu (Hendikawati, 2014). Saat memprediksi data deret waktu, penting untuk mempertimbangkan jenis atau pola data. Ada empat jenis pola data deret waktu, yaitu pola horizontal adalah kejadian yang tidak terduga dan acak, pola tersebut dapat berdampak pada fluktuasi data deret waktu. Pola trend adalah kecenderungan arah data dalam jangka panjang yang dapat berbentuk kenaikan atau penurunan. Pola musiman adalah fluktuasi data yang terjadi secara teratur dalam satu tahun, seperti setiap triwulan, setiap bulan, atau setiap hari. Sementara pola siklis adalah fluktuasi dari data selama periode waktu yang lebih lama.



Gambar 1. Pola Data *Time series*

2.2.2 Model Data Deret Waktu ARIMA

Metode runtun waktu Box-Jenkins adalah nama lain dari *Autoregressive Integrated Moving Average*. ARIMA menggunakan nilai historis dan nilai saat ini dari variabel dependen untuk menghasilkan prakiraan jangka pendek yang akurat. ARIMA memiliki ketepatan yang sangat baik untuk peramalan jangka pendek, namun peramalan tersebut kurang baik untuk peramalan jangka panjang. Biasanya cenderung mendatar atau konsisten untuk waktu yang cukup lama.

Model ARIMA merupakan model peramalan yang tidak menggunakan pengaruh antar variabel seperti pada model regresi, sehingga penjelasan variabel dependen dan independen tidak diperlukan dalam model ARIMA. Box dan Jenkins pertama kali memperkenalkan model ARIMA pada tahun 1976. Proses *Autoregressive* (AR) orde p , proses *Moving Average* (MA) orde q , atau campuran keduanya dapat ditemukan dalam model ARIMA. Karena komponen AR dan MA dari model ARIMA memerlukan data yang stasioner, maka proses *difference* orde d diterapkan jika data deret waktu tidak stasioner.

Pendugaan model ARIMA dilakukan sebagai berikut. Komponen terintegrasi dan model ARMA dipisahkan menjadi dua bagian terlebih dahulu. Komponen kedua (ARMA) kemudian dibagi menjadi dua bagian, yaitu *Moving Average* (MA) dan *Autoregressive* (AR). Komponen AR membandingkan nilai sekarang deret waktu tertentu dengan nilai sebelumnya sepanjang waktu. Komponen MA menyajikan panjang pengaruh dengan mengkorelasikan nilai acak pada saat sekarang dengan waktu yang lalu. Jika deret $\{W_t\}$ mengikuti model ARMA (p,q) dapat dikatakan bahwa $\{Y_t\}$ adalah proses ARIMA (p,d,q) . Sebuah konstanta rata-rata tak nol, θ_0 , dalam model stasioner ARMA $\{W_t\}$ dapat diakomodasikan dengan cara:

$$W_t = \theta_0 + \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.1)$$

dimana:

θ_0 = konstanta

ϕ_p = parameter yang menjelaskan *autoregressive* (AR)

θ_q = parameter yang menjelaskan *moving average* (MA)

e_t = galat pada waktu ke- t yang diasumsikan menyebar normal

p = derajat *Autoregressive* (AR)

q = derajat *Moving Average* (MA)

d = derajat pembeda

t = waktu

1. Identifikasi Kestasioneran Data

Hanya deret waktu stasioner yang dapat digunakan dengan model ARIMA. Oleh karena itu, langkah pertama adalah memeriksa apakah data deret waktu stasioner. Diferensiasi dilakukan jika data *time series* tidak stasioner. Diferensiasi adalah proses pengurangan data pada waktu t dengan data pada waktu $t-1$ dengan tujuan untuk mengetahui perubahan atau perbedaan nilai pengamatan. Transformasi data biasanya berbentuk Ln (Natural logaritma) atau akar kuadrat untuk menyelesaikan masalah data dengan variasi non-stasioner. Dampak musiman juga dapat menghasilkan data varians yang tidak stasioner, sehingga jika pengaruh musiman dihilangkan maka data tersebut dapat menjadi data stasioner (Makridakis et al, 1999).

2. Autokorelasi

Korelasi antara X_t dan X_{t+k} (dimana k merupakan *lag*) dikenal sebagai autokorelasi. Data deret waktu biasanya menunjukkan autokorelasi karena, menurut sifatnya, data saat ini dipengaruhi oleh data dari waktu sebelumnya (Firdaus, 2004). Machmudin & Brodjol (2012) menyebutkan bahwa terdapat dua jenis fungsi autokorelasi, yaitu:

a. Autocorrelation Function (ACF)

Autocorrelation Function (ACF) adalah suatu hubungan linier antara pengamatan Z_t dengan pengamatan Z_{t-k} . Koefisien autokorelasi dan korelogramnya dapat digunakan untuk mendeteksi data yang tidak stasioner. Koefisien autokorelasi adalah pengukuran seberapa dekat nilai-nilai variabel yang sama selama berbagai periode waktu terkait secara linier.

$$\hat{\rho}_k = r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^{n-k} (Z_t - \bar{Z})^2} \quad (2.2)$$

b. Partial Autocorrelation Function (PACF)

Partial Autocorrelation Function (PACF) digunakan untuk menunjukkan ukuran hubungan antara nilai variabel yang sama, dengan menganggap pengaruh dari semua kelambatan waktu lainnya tetap konstan.

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j} \quad (2.3)$$

dimana:

$$\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j} \quad \text{untuk } j=1,2,\dots,k-1$$

2.3 Data Mining

Data mining adalah metode untuk mengidentifikasi dan mengekstrak informasi yang bermanfaat dan pengetahuan terkait dari *database* besar menggunakan teknik statistik, matematika, kecerdasan buatan, dan pembelajaran mesin (Turban, 2005). Han et al (2011) menegaskan bahwa data mining secara garis besar dapat dibagi menjadi dua jenis, yaitu:

1. Prediksi

Prediksi merupakan proses menemukan pola dari data dengan menerapkan berbagai variabel tambahan di masa depan. Memprediksi nilai properti tertentu berdasarkan nilai atribut lain adalah tujuan dari tugas prediksi. Atribut yang diprediksi dikenal sebagai target atau variabel dependen sedangkan atribut yang digunakan untuk menghasilkan prediksi disebut sebagai variabel independen.

2. Deskripsi

Deskripsi dalam data mining yaitu proses menemukan atribut data yang signifikan dalam database. Menurunkan pola (korelasi, tren, klaster, teritori, dan anomali) yang memadatkan hubungan pokok dalam data adalah tujuan dari tugas deskripsi. Tugas dari data mining deskripsi yaitu penyelidikan, dan sering kali membutuhkan metode *post-processing* untuk validasi dan pembenaran hasil.

Manfaat menggunakan data mining sebagai teknik analisis antara lain:

- a. Ini dapat menangani kumpulan data yang luas dan kompleks.
- b. Data mining dapat bekerja dengan data termasuk berbagai properti.
- c. Karena teknik data mining tertentu menuntut parameter yang harus dimasukkan secara manual oleh pengguna, data mining dapat mengidentifikasi dan menganalisis data secara otomatis.
- d. Data mining dapat digunakan untuk meningkatkan akurasi dan hasil analisis agar mendapatkan hasil yang terbaik.

2.4 *Machine Learning*

Machine Learning atau pembelajaran mesin adalah teknik dalam AI yang sering digunakan untuk mengotomatisasi tugas atau menggantikan atau meniru perilaku manusia. Pembelajaran mesin mencoba meniru bagaimana makhluk cerdas, seperti manusia, belajar dan menggeneralisasi proses. Pembelajaran mesin memiliki setidaknya dua aplikasi utama, yaitu klasifikasi dan prediksi. Proses pelatihan atau *training* adalah fitur pembeda dari pembelajaran mesin. Akibatnya, pembelajaran mesin membutuhkan data pelatihan untuk mempelajari sesuatu. Klasifikasi adalah metode dalam pembelajaran mesin yang digunakan oleh mesin untuk mengklasifikasikan item berdasarkan fitur tertentu, seperti halnya manusia mencoba membedakan satu objek dari objek lainnya. Sementara itu prediksi digunakan oleh mesin untuk meramalkan hasil data *input* berdasarkan data pelatihan. *Support Vector Machine* (SVM), Sistem Pengambilan Keputusan, dan *Neural networks* adalah metode *machine learning* yang paling banyak digunakan (Ahmad, 2017).

Metode pembelajaran terawasi (*supervised learning*) dan metode pembelajaran tak terawasi (*unsupervised learning*) adalah dua metode algoritma pembelajaran (Fausett, 1994).

1. *Supervised Learning*

Metode ini digunakan ketika nilai keluaran yang diinginkan diketahui sebelumnya. Nilai keluaran jaringan ini akan dibandingkan dengan nilai keluaran yang diinginkan yang disebut eror. Jika eror masih signifikan, artinya harus diperiksa kembali sampai nilai eror yang rendah tercapai atau nilai keluaran jaringan hampir tidak berbeda dari nilai keluaran yang diinginkan. *Adaline*, *backpropagation*, *hapfield*, *boltzman*, *perceptron*, dan *hebbian* (*hebb rule*) adalah contoh algoritma yang menggunakan teknik pembelajaran terawasi.

2. *Unsupervised Learning*

Istilah metode pembelajaran tanpa pengawasan mengacu pada jenis pembelajaran yang tidak memerlukan referensi ke nilai keluaran yang

diinginkan. Metode ini hanya menentukan nilai bobot dalam rentang berdasarkan nilai *input* yang diberikan, namun nilai keluaran yang diinginkan tidak diketahui. Penerapan metode ini sebanding dengan klasifikasi, karena tujuan mendasar dari metode ini adalah untuk mengelompokkan *unit* yang memiliki kesamaan di area tertentu. *Hebbian*, *competitive*, *kohonen*, LVQ (*Learning Vector Quantization*), dan *neocognitron* adalah contoh yang menggunakan metode pembelajaran tanpa pengawasan.

2.5 *Artificial Neural Network* (ANN)

2.5.1 Pengertian *Artificial Neural Network* (ANN)

Sistem pemrosesan informasi yang menyerupai jaringan saraf biologis dikenal sebagai *Artificial Neural Network* (ANN) atau jaringan saraf tiruan. Asumsi berikut mendasari pengembangan *Artificial Neural Network* (ANN), yang merupakan representasi matematis umum dari *neuron* biologis manusia (Fausett, 1994):

1. Pemrosesan informasi terjadi pada banyak elemen sederhana yang disebut *neuron*.
2. Sinyal diberikan antara *neuron* melalui penghubung-penghubung.
3. Penghubung antar *neuron* memiliki bobot yang akan memperkuat atau memperlemah sinyal.
4. Setiap *neuron* menerapkan fungsi aktivasi terhadap jumlah sinyal masukan terbobot untuk menentukan sinyal keluarannya.

Ciri-ciri berikut dari jaringan saraf tiruan:

1. Pola hubungan antar *neuron* yang disebut arsitektur.
2. Metode penentuan bobot pada hubungan yang disebut pelatihan (*training*) atau pembelajaran (*learning*) atau algoritme.
3. Fungsi aktivasi yang dijalankan masing-masing *neuron* pada *input* jaringan untuk menentukan *output*.

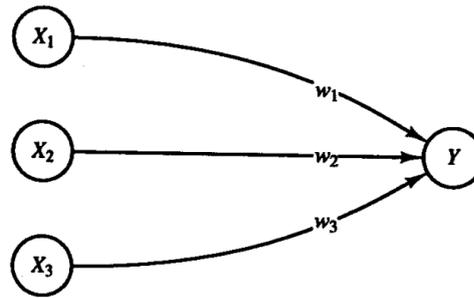
Jaringan saraf tiruan terdiri dari sejumlah besar elemen pemrosesan sederhana yang disebut *neuron*, *units*, *cells*, atau *nodes*. Setiap *neuron* terhubung ke *neuron* lain melalui hubungan komunikasi terarah, masing-masing dengan bobot yang terkait. Bobot mewakili informasi yang digunakan oleh jaringan untuk memecahkan masalah. Jaringan saraf tiruan dapat diterapkan untuk berbagai macam masalah, seperti menyimpan dan memanggil kembali data atau pola, mengklasifikasikan pola, melakukan pemetaan umum dari pola *input* ke pola *output*, mengelompokkan pola yang serupa, atau menemukan solusi untuk masalah optimasi terbatas.

Setiap *neuron* memiliki keadaan internal, yang disebut tingkat aktivasi atau aktivitasnya, yang merupakan fungsi dari *input* yang diterimanya. Biasanya, sebuah *neuron* mengirimkan aktivasinya sebagai sinyal ke beberapa *neuron* lain. Penting untuk dicatat bahwa *neuron* hanya dapat mengirim satu sinyal pada satu waktu, meskipun sinyal itu disiarkan ke beberapa *neuron* lain.

Sebagai contoh, dapat dilihat *neuron* Y, diilustrasikan pada Gambar 2, yang menerima *input* dari *neuron* X₁, X₂, dan X₃. Aktivasi (sinyal *output*) dari *neuron* ini adalah X₁, X₂, dan X₃, masing-masing. Bobot pada penghubung dari X₁, X₂, dan X₃ ke *neuron* Y berturut-turut adalah w₁, w₂, dan w₃. *Input* jaringan, y_{in}, ke *neuron* Y adalah jumlah dari bobot sinyal dari *neuron* X₁, X₂, dan X₃, yaitu,

$$y_{in} = w_1x_1 + w_2x_2 + w_3x_3 \quad (2.4)$$

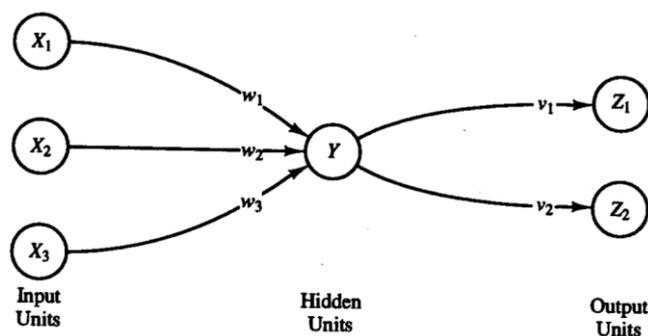
Informasi yang diberikan ke *Artificial Neural Network* (ANN) akan ditransmisikan oleh lapisan *neuron*, dari *input layer* ke *output layer* melalui lapisan lainnya. *Hidden layer* adalah nama yang diberikan untuk yang satu ini. Berikut adalah arsitektur jaringan saraf sederhana (Fausett, 1994).



Gambar 2. *Artificial Neuron* sederhana

Sekarang misalkan lebih lanjut bahwa *neuron* Y terhubung ke *neuron* Z_1 dan Z_2 , dengan bobot v_1 dan v_2 , seperti yang ditunjukkan pada Gambar 3. *Neuron* Y mengirimkan sinyal y ke masing-masing *neuron* ini. Namun pada umumnya nilai yang diterima oleh *neuron* Z_1 dan Z_2 akan berbeda, karena setiap sinyal diskalakan dengan bobot yang sesuai, v_1 dan v_2 . Dalam jaringan yang khas, aktivasi z_1 dan z_2 dari *neuron* Z_1 dan Z_2 akan bergantung pada *input* dari beberapa atau bahkan banyak *neuron*, bukan hanya satu, seperti yang ditunjukkan dalam contoh sederhana ini.

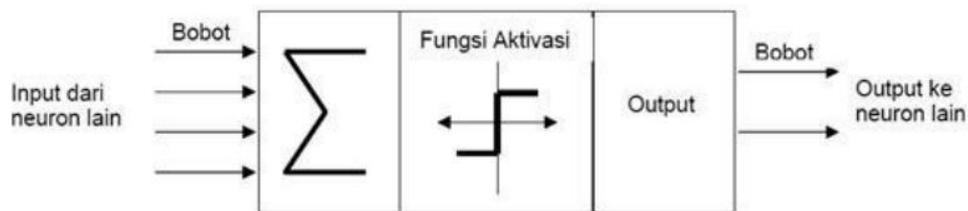
Meskipun *neural network* pada Gambar 3 sangat sederhana, kehadiran *hidden neuron*, bersama dengan fungsi aktivasi nonlinier, memberikannya kemampuan untuk memecahkan lebih banyak masalah daripada yang dapat diselesaikan oleh jaringan dengan hanya *neuron input* dan *output*. Di sisi lain, lebih sulit untuk melatih (menemukan nilai optimal untuk bobot) jaringan dengan *hidden neuron*.



Gambar 3. *Neural Network* sederhana

2.5.2 Komponen-Komponen *Artificial Neural Network* (ANN)

Penelitian Kusumadewi (2003) menjelaskan bahwa jaringan saraf tiruan terdiri dari banyak *neuron* dan memiliki hubungan di antara mereka yang dikenal sebagai bobot, seperti halnya otak manusia. Berikut adalah struktur neuron jaringan syaraf tiruan.



Gambar 4. Struktur *Neuron Artificial Neural Network*

Berdasarkan Gambar 4 dapat dijelaskan komponen-komponen *Artificial Neural Network* (ANN) sebagai berikut.

1. *Input* : seperti halnya Otak manusia memiliki dendrit yang bertindak sebagai reseptor untuk informasi yang datang dari *neuron* lain..
2. *Neuron* : sel pemrosesan informasi.
3. *Bobot* : sama halnya synopsis di otak manusia yang memiliki fungsi yang sama untuk menggambarkan kekuatan hubungan antara suatu *neuron* dengan *neuron* lain.
4. *Fungsi aktivasi* : nilai tertentu yang memetakan fungsi hasil penjumlahan yang diterima oleh semua *input* dari suatu *neuron*.
5. *Output* : sama seperti akson pada otak manusia yang sama-sama berfungsi sebagai proses pembelajaran atau proses perhitungan suatu fungsi aktivasi yang akan menghasilkan *output* dari jaringan yang telah dimasukkan atau bahkan berfungsi sebagai bagi *neuron* yang lain.

2.5.3 Arsitektur *Artificial Neural Network* (ANN)

Arsitektur net mengacu pada konfigurasi *neuron* dan pola koneksi antar *layer*. Kusumadewi (2003) mengklaim bahwa terdapat tiga jenis arsitektur jaringan saraf tiruan: *single layer*, *multilayer*, dan *competitive layer*. *Layer input* dikecualikan dari perhitungan jumlah *layer* yang digunakan untuk menentukan banyak *layer* yang digunakan.

a. *Single Layer Network*

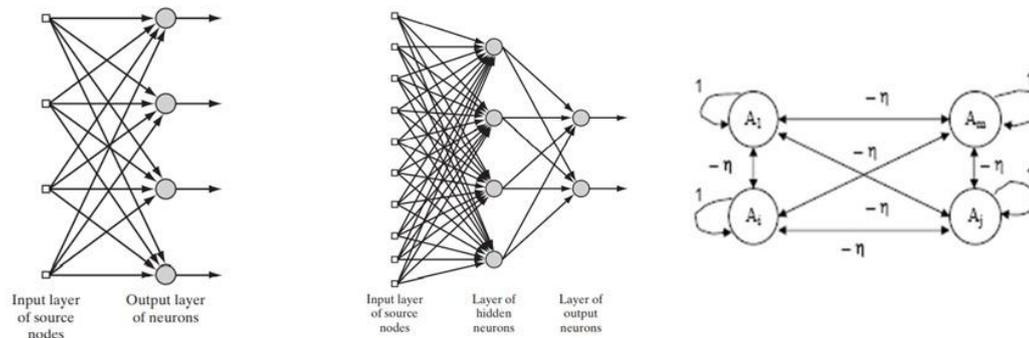
Single layer network berisi satu *layer* untuk menghubungkan nilai bobot. Hubungan antara *neuron input* dan *neuron output* adalah langsung. Jaringan ini hanya menerima informasi dan dengan cepat mengubahnya menjadi *output* tanpa melewati *hidden layer*. Satu *input layer* dan satu *output layer* yang membentuk jaringan lapisan tunggal ini adalah fitur yang membedakannya.

b. *Multilayer Network*

Multilayer network adalah jaringan yang memiliki satu atau lebih lapisan yang berada di antara *input layer* dan *output layer* (*hidden layer*). Masalah yang lebih kompleks dapat diselesaikan dengan jaringan *multilayer* daripada dengan jaringan *single layer*.

c. *Competitive Layer Network*

Dua atau lebih *Artificial Neural Network* (ANN) membentuk *Competitive Layer Network*. Satu *neuron* dapat dihubungkan ke yang lain menggunakan arsitektur jaringan ini (Fausett, 1994).



Gambar 5. Struktur *Single Layer*, *Multilayer*, dan *Competitive Layer Network*

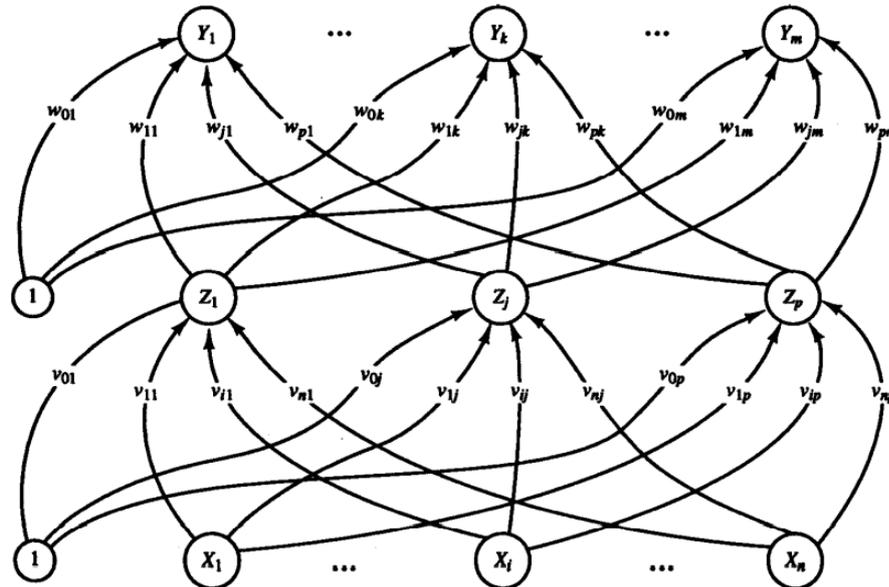
2.6 *Artificial Neural Network dengan Algoritma Backpropagation*

Salah satu algoritma *Artificial Neural Network* yang sering digunakan untuk mengatasi masalah peramalan adalah metode *backpropagation*. Hal ini dimungkinkan karena metode *backpropagation* adalah salah satu bentuk pendekatan pelatihan ANN terbimbing. Pola masukan dan pola yang diinginkan disajikan ke jaringan sebagai sepasang pola. Ketika suatu pola dimasukkan ke dalam jaringan, bobotnya disesuaikan untuk mengurangi perbedaan antara pola keluaran dan pola yang diinginkan. Proses *training* ini dilakukan berulang kali untuk memastikan bahwa pola yang diinginkan dipenuhi oleh setiap pola yang dikeluarkan oleh jaringan. Arsitektur jaringan ini terdiri dari *input layer*, *hidden layer*, dan *output layer* (Fausett, 1994).

Fausett (1994) menjelaskan di dalam bukunya bahwa pelatihan *backpropagation* terdapat tiga tahapan yang dilalui antara lain umpan maju (*feedforward*), umpan mundur/propagasi eror (*backpropagation of error*), dan modifikasi bobot serta *bias* (*adjustment*). Cara kerja *backpropagation* ini pertama mencari eror keluarannya dengan arah maju (*forward*) untuk memperbaiki bobot-bobot yang kemudian dilakukan dengan arah mundur (*backward*). Pada saat melakukan *forward* akan ada fungsi aktivasi yang akan mengaktifkan *neuron-neuron* guna menghasilkan keluaran. Fungsi aktivasi yang digunakan pada *backpropagation* umumnya yang bersifat kontinu, terdiferensial, dan tidak turun.

Backpropagation neural network digambarkan pada Gambar 6 dengan n input (ditambah *bias*), *hidden layer* yang terdiri dari p neuron (ditambah *bias*), dan m neuron output.. Di mana v_{ij} adalah bobot garis yang menghubungkan *neuron input* x_i ke *neuron hidden layer* z_j (v_{0j} merupakan bobot garis yang menghubungkan *bias* pada *neuron input* ke *neuron hidden layer* z_j), w_{jk} yakni bobot dari *neuron hidden layer* z_j ke *neuron output* y_k (w_{0k} adalah bobot dari *bias* di *hidden layer* ke *neuron*

output y_k) (Fausett 1994). Adapun arsitektur ANN dengan algoritma *backpropagation* adalah sebagai berikut.



Gambar 6. *Backpropagation neural network* dengan satu *hidden layer*

Berikut adalah persamaan *backpropagation*:

$$y = \sum_{k=1}^m \psi_h (w_{0k} + \sum_{j=1}^p w_{jk} \psi_o (v_{0j} + \sum_{i=1}^n v_{ij} x_i)) \quad (2.5)$$

dimana:

x_i : input jaringan ke- i

v_{0j} : bobot *bias* pada *input layer* ke *hidden layer* ke- j

w_{0k} : bobot *bias* pada *hidden layer* ke *output layer*

v_{ij} : bobot pada *input layer* ke- i ke *hidden layer* ke- j

w_{jk} : bobot pada *hidden layer* ke- j ke *output layer*

ψ_o : fungsi aktivasi yang digunakan pada *hidden layer*

ψ_h : fungsi aktivasi yang digunakan pada *output layer*

2.7 Parameter *Artificial Neural Network* (ANN)

2.7.1 *Hyperparameter Optimizer*

Hyperparameter Optimizer adalah parameter dalam model *neural network* yang ditentukan di awal dan tetap konstan selama proses pelatihan (Michelucci, 2018). *Hyperparameter* yang umum digunakan dalam *neural network*, yaitu jumlah *hidden layer*, jumlah *nodes* dalam *hidden layer*, *dropout*, *epoch* dan *batch size*, fungsi aktivasi, dan lain sebagainya

Parameter harus dikombinasikan dengan cara yang ideal untuk memilih model *neural network* yang optimal. Mencari kombinasi terbaik akan memakan banyak waktu karena pelatihan harus dilakukan pada setiap kombinasi, jadi diperlukan suatu metode untuk mengidentifikasi kombinasi terbaik dengan jumlah pelatihan paling sedikit untuk mempersingkat waktu. *Hyperparameter tuning* atau *hypertuning* akan menggunakan *early stopping* sehingga ketika kondisi terpenuhi, proses pembelajaran model berakhir (Li et al, 2018).

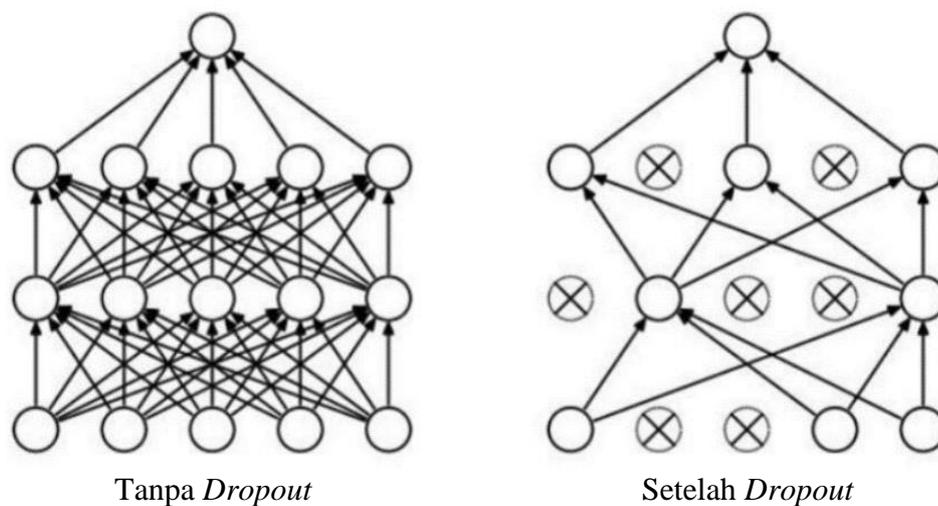
2.7.2 *Hidden Layer*

Heaton (2008) menyatakan perubahan hasil pelatihan akan bergantung pada jumlah *hidden layer* yang digunakan. *Output* akan kurang baik jika jumlah *neuron* terlalu sedikit, sedangkan jumlah *neuron* yang terlalu banyak akan memperlambat dan mungkin terjadi pelatihan yang tak hingga. Berikut adalah beberapa prinsip umum untuk mengetahui berapa banyak *hidden layer* yang sesuai:

1. Jumlah *hidden layer* lebih banyak dari jumlah *neuron input* atau *output*.
2. Jumlah *hidden layer* seharusnya $\frac{2}{3}$ besar dari jumlah total *neuron input* dan *output*.
3. Jumlah *hidden layer* harus lebih sedikit atau sama dengan dua kali jumlah *input layer*.

2.7.3 Dropout

Dropout adalah metode sederhana yang digunakan untuk mencegah *overfitting* (Srivastava et al, 2014). Teknik yang digunakan adalah regulasi *neural network* dimana *dropout* tidak memodifikasi *loss function*, tetapi memodifikasi *neural network* dengan memutuskan sementara *neuron* dari suatu *layer* dengan *probability (rate)* tertentu selama proses *training*.



Gambar 7. *Neural network* tanpa *dropout* dan setelah menggunakan *dropout*

Pemutusan *neuron* secara acak di jaringan menyebabkan lapisan yang terputus memperbaiki kesalahan sebelumnya, sehingga menghasilkan kinerja model yang optimal atau mengurangi *overfitting*. *Dropout* yang digunakan untuk menghasilkan model yang optimal biasanya 0.2 hingga 0.5, menyiratkan bahwa 20% hingga 50% *neuron* dalam jaringan terputus secara acak. Namun, pemutusan terlalu banyak *neuron* akan mengakibatkan ketidakseimbangan jaringan dan kegagalan untuk mencapai *output* yang diinginkan.

2.7.4 Epoch dan Batch Size

Vijayalakshmi & Venkatachalapathy (2019) berkata bahwa jumlah iterasi selama proses pelatihan yang memberikan *input* dari jaringan dan juga bobot jaringan diperbarui disebut sebagai *epoch*. Proses pelatihan diulang pada *neural network* dari awal lagi. Satu *epoch* selama proses pelatihan dapat berlangsung cukup lama, sehingga pembagian dilakukan setiap *batch*, yang disebut dengan *batch size*, untuk mempercepat proses pelatihan. Jumlah sampel pelatihan yang digunakan dalam satu iterasi disebut sebagai *batch Size*. Dalam pembelajaran mesin, ini adalah salah satu *hyperparameter* paling penting untuk menyesuaikan sistem *deep learning* (Rochmawati dkk, 2021). Dengan mempertimbangkan kelipatan 2, nilai yang umum digunakan adalah 16, 32, dan 64, yang dapat membantu dalam proses pembagian *dataset* dalam pelatihan model menjadi lebih sederhana.

2.7.5 Fungsi Aktivasi

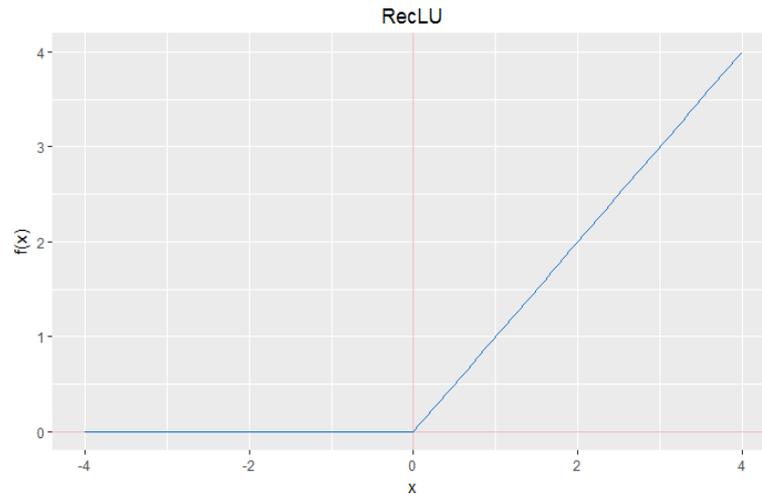
Fungsi aktivasi dalam *Artificial Neural Network* (ANN) berperan sebagai sinyal untuk menentukan *output* ke beberapa *neuron* lain. Dalam *Artificial Neural Network* (ANN), fungsi aktivasi ini sangat penting karena penggunaannya ditentukan oleh kebutuhan dan target yang diinginkan serta dalam menentukan jumlah bobot. Fungsi aktivasi *Rectified Linear Unit* dan *Sigmoid* adalah dua fungsi aktivasi yang umum digunakan. (Puspitaningrum, 2006).

a. *Rectified Linear Unit* (ReLU)

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

$$f(x) = \max(0, x) \quad (2.6)$$

Setiap *input* negatif yang diberikan akan selalu dipetakan ke 0 dan setiap *input* positif yang diberikan akan mempertahankan nilainya, sehingga tidak terdapat hasil yang bernilai negatif. Grafik fungsi aktivasi ReLU adalah sebagai berikut:



Gambar 8. Fungsi Aktivasi ReLU

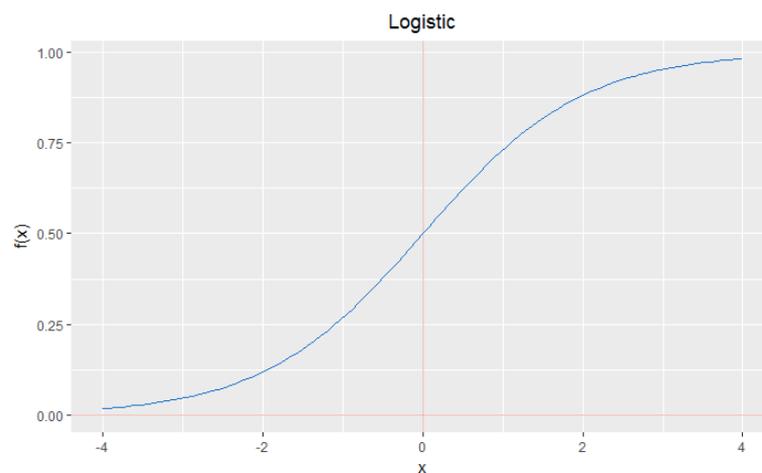
b. *Sigmoid*

Fungsi aktivasi yang umum dalam *Artificial Neural Network* (ANN) menggunakan algoritma *backpropagation* adalah fungsi sigmoid. Fungsi ini mengambil kisaran antara 0 sampai 1. Bentuk dari fungsi sigmoid yaitu:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.7)$$

dengan turunan

$$f'(x) = f(x)(1 - f(x)) \quad (2.8)$$



Gambar 9. Fungsi aktivasi *Sigmoid*

2.7.6 Weight (W)

Bobot ANN berfungsi sebagai penghubung antar lapisan dan mengalikan nilai yang diterima dari *input*. Bobot dapat diubah sedemikian rupa sehingga menghasilkan *output* yang diinginkan dari nilai *input* tertentu. Menginisiasi nilai awal bobot dapat dilakukan secara acak dalam rentang -1 hingga 1, atau -0,5 hingga 0,5 (Haykin, 1994). Rumus berikut dapat digunakan untuk menghitung bobot.

$$W = \left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right) \quad (2.9)$$

dimana :

F_i : nilai total variabel / *nodes* pada *input layer*

2.7.7 Bias (θ)

Nilai *bias* adalah derajat ketidakpastian pada *node layer* tertentu. Setiap *node* di *hidden layer* memiliki *bias* yang diberikan padanya (Haykin, 1994). Rumus berikut dapat digunakan untuk menemukan nilai inisiasi bias:

$$\theta = \left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right) \quad (2.10)$$

dimana :

F_i : nilai total *nodes* pada *hidden layer*

2.8 Validasi Model

Hanke & Wichern (2014) mengklaim bahwa metode peramalan yang menggabungkan data kuantitatif dengan data deret waktu tertentu menciptakan ketidakakuratan. Oleh karena itu, diperlukan suatu metode untuk mengukur jumlah eror yang dapat dihasilkan oleh metode peramalan sebelum suatu keputusan dibuat. Metode berikut dapat digunakan untuk menilai kesalahan teknik peramalan, yaitu MSE (*Mean Square Error*), RMSE (*Root Mean Square Error*), MAD (*Mean*

Absolute Derivation), MAPE (*Mean Absolute Percentage Error*), dan MPE (*Mean Percentage Error*).

a. *Mean Squared Error* (MSE)

Mean Squared Error (MSE) adalah teknik untuk menghitung eror yang mengkuadratkan nilai eror untuk setiap interval. Nilai MSE yang lebih rendah menunjukkan model yang lebih stabil saat mencari model ANN. Rumus berikut dapat digunakan untuk menentukan MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y'_i - Y_i)^2 \quad (2.11)$$

dimana :

n : Jumlah sampel

Y' : Nilai aktual indeks

Y : Nilai prediksi

b. *Root Mean Square Error* (RMSE)

Root Mean Square Error (RMSE) adalah jarak rata-rata antara nilai yang diprediksi dan diamati, diukur dalam satuan variabel target.

$$RMSE = \sqrt{MSE} \quad (2.12)$$

c. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error (MAPE) adalah teknik untuk menentukan eror dengan membagi kesalahan mutlak untuk setiap periode dengan nilai aktual yang diamati selama periode tersebut. Persentase kesalahan mutlak kemudian harus dirata-ratakan. Dalam hal menghitung eror, MAPE lebih baik dari MSE. Rumus di bawah ini dapat digunakan untuk menentukan MAPE:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_t - f_t}{x_t} \right|}{n} \times 100\% \quad (2.13)$$

Dimana :

n : Jumlah sampel

x_t : Nilai aktual indeks pada periode ke- t

f_t : Nilai prediksi indeks pada periode ke- t

2.9 Inflasi

Kecenderungan harga untuk naik secara konsisten dan umumnya di semua kategori barang dan jasa disebut sebagai inflasi. Berdasarkan definisi ini, kenaikan harga produk tertentu tidak dapat disebut sebagai inflasi. Salah satu indikator penting untuk menilai perekonomian suatu negara adalah inflasi. Hal ini karena inflasi memiliki dampak negatif yang signifikan terhadap perekonomian suatu negara, seperti kenaikan harga, penurunan daya beli, perubahan pasar tenaga kerja, dan lainnya. Sementara itu, inflasi dipengaruhi oleh upah, harga barang dan jasa, dan suku bunga. Jumlah peredaran uang secara berlebihan di masyarakat akan menyebabkan tingginya nilai inflasi atau disebut hiperinflasi (Mankiw, 2007).

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 pada penelitian ini adalah data sekunder yang diperoleh dari Bank Indonesia. Data tersebut merupakan data bulanan inflasi di Indonesia periode Januari 2003 hingga Desember 2019.

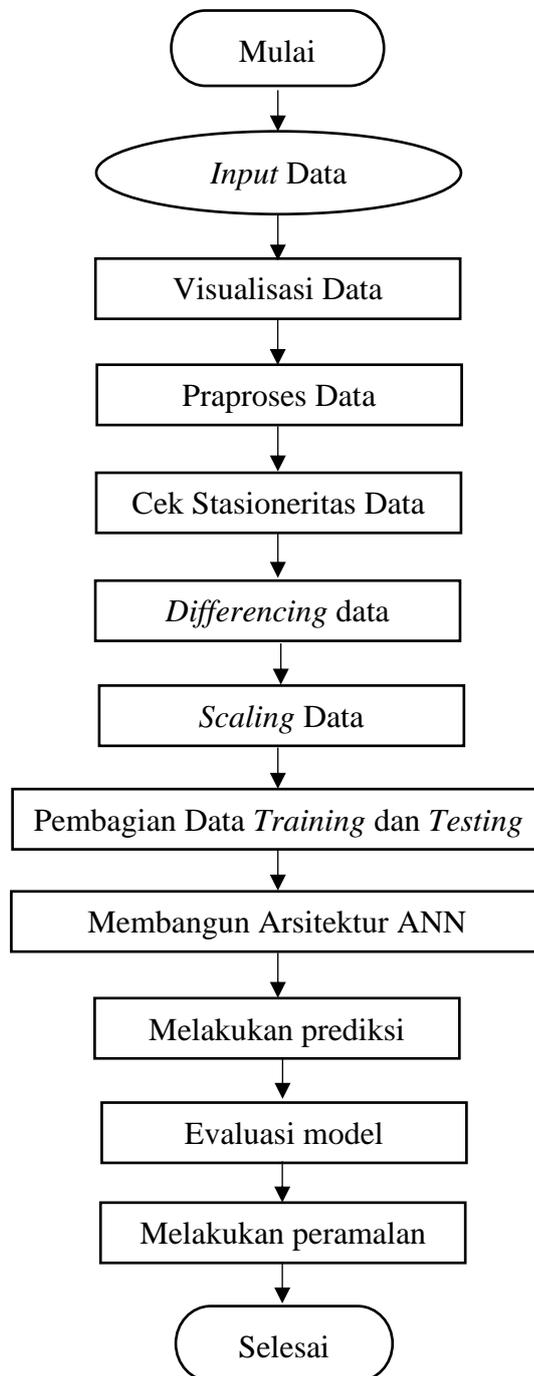
3.3 Metode Penelitian

Dalam penelitian ini akan dicari model *Artificial Neural Network* (ANN) untuk memprediksi inflasi di Indonesia menggunakan algoritma *backpropagation* dengan bantuan *software python*. Setelah itu akan dievaluasi berdasarkan nilai eror terkecil dari fungsi aktivasi yang digunakan. Adapun langkah-langkah penelitian ini yaitu:

1. Memasukkan (*input*) data inflasi di Indonesia ke dalam *software python*.
2. Melakukan visualisasi data.
3. Melakukan praproses data untuk melihat adanya *missing value* dari data tersebut.

4. Melihat stasioneritas data dari korelogram ACF dan PACF.
5. Melakukan *differencing* data untuk menstasionerkan data dan mendapatkan data *lag*.
6. Melakukan *scaling* data.
7. Pembagian data *training* sebanyak 70% dan data *testing* sebanyak 30%.
8. Membangun arsitektur *Artificial Neural Network* (ANN) dengan algoritma *backpropagation*.
9. Melakukan prediksi pada data *testing*.
10. Melakukan evaluasi model prediksi dengan melihat nilai RMSE, MAPE, dan Akurasi yang diperoleh.
11. Melakukan peramalan selama 9 bulan.

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



V. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dilakukan, dapat diambil kesimpulan sebagai berikut:

1. Metode *Artificial Neural Network* (ANN) dapat digunakan untuk memprediksi tingkat Inflasi Indonesia menggunakan 1 *layer input* dengan 1 *nodes* yaitu data *lag k=1*, serta 2 *hidden layer* dengan 128 *nodes* untuk *hidden layer* pertama dan 96 *nodes* untuk *hidden layer* kedua, lalu menghasilkan 1 *output layer* dengan 1 *nodes*, yaitu data hasil prediksi Inflasi di Inonesia. Pada penelitian ini dibangun menggunakan fungsi aktivasi ReLU. Setelah itu, dilakukan pengujian *hypertuning*, didapatkan nilai *loss* terkecil, yaitu 0.027254 dan didapatkan jumlah *dropout*, *epoch* dan jumlah *batch size* terbaik, yaitu *dropout* dengan jumlah 0.2, *epoch* dengan jumlah 50, dan *batch size* dengan jumlah 16. Pengujian arsitektur menunjukkan nilai *loss* dan *validation loss* mengalami penurunan dan berimpit satu dengan yang lainnya, artinya arsitektur yang dihasilkan sudah optimal atau tidak mengalami *overfitting*..
2. Hasil prediksi dengan menggunakan metode *Artificial Neural Network* pada data Inflasi Indonesia menghasilkan nilai RMSE sebesar 0.042, nilai MAPE sebesar 0.161 % dan nilai akurasi sebesar 99.83 % sehingga dapat diartikan bahwa nilai tersebut memiliki kemampuan prediksi yang baik dengan nilai akurasi sebesar 99.83% dan metode ini dapat digunakan untuk melakukan peramalan yang akan datang.

DAFTAR PUSTAKA

- Ahmad, A. 2017. Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning. *Jurnal Teknologi Indonesia*. Yayasan Cahaya Islam.
- Fausett, L. 1994. *Fundamentals of Neural Networks: Achitectures, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Firdaus, M. 2004. *Ekonometrika Suatu Pendekatan Aplikatif*. Bumi Aksara, Jakarta.
- Han, J., Kamber, M., & Pei, J. 2012. *Data Mining Concepts and Techniques*. 3rd Ed. Elsevier Inc, San Fransisco.
- Hanke, J.E., & Wichern, D. 2014. *Business Forecasting*. 9th Edition. Pearson Education, New York.
- Haykin, S. 1994. *Neural Network: A Comprehensive Foundation*. 2nd Ed. Pearson Education, New York.
- Heaton, J. 2008. *Introduction to Neural Network for Java*. 2nd Ed. Heaton Research Inc, Florida.
- Hendikawati, P. 2014. *Algoritma Levenberg-Marquardt Untuk Training Feedforward Neural Network Pada Peramalan Data Time series*. Jurusan Matematika FMIPA UGM, Yogyakarta.
- Herdianto. 2013. *Prediksi Kerusakan Motor Induksi Menggunakan Metode Jaringan Saraf Tiruan Backpropagation*. Tesis. Universitas Sumatera Utara, Medan.

- Kusumadewi, S. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu, Yogyakarta.
- Li, L., Jamieson, K., Desalvo, G., Rostamizadeh, A., & Talwalkar, A. 2018. Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *Journal of Machine Learning Research*. **18**(2018): 1-52.
- Machmudin, A. & Brodjol, S.S.U. 2012. Peramalan Temperatur Udara Di Kota Surabaya Dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni ITS*. **1**(1): 118-123.
- Makridakis, S., Wheelwright, S.C., & McGee, V.E. 1999. *Metode dan Aplikasi Peramalan*. Ed. ke-2. Terjemah Untung Sus Andriyanto. Erlangga, Jakarta.
- Mankiw, N.G. 2007. *Teori Makroekonomi*. Ed. ke-6. Terjemah Iman N. Erlangga, Jakarta.
- Martanto, B., Tan, S., & Hidayat, M.S. 2021. Analisis tingkat inflasi di Indonesia Tahun 1998-2020 (pendekatan error correction model). *Jurnal Paradigma Ekonomika*. **16**(3): 619-632.
- Michelucci, U. 2018. *Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Network*. Apress Berkeley, California.
- Nakamura, E. 2004. Inflation Forecasting Using a Neural Network. *Economics Letters*. **86**(2005): 373-378.
- Puspitaningrum, D. 2006. *Pengantar Jaringan Syaraf Tiruan*. Andi, Yogyakarta.
- Rochmawati, N., Hidayati, H.B., Yamasari, Y., Tjahyaningtjas, H.P.A., Yustanti, W., & 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.
- Silfiani, M. & Suhartono. 2013. Aplikasi Metode Ensemble untuk Peramalan Inflasi di Indonesia. *Jurnal Sains dan Seni ITS*. **1**(1): 171-176.

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. **15**(2014): 1929-1934.
- Turban. E. 2005. *Decision Support System and Intelligent System (Sistem Pendukung Keputusan dan Sistem Cerdas)*. Andi, Yogyakarta.
- Vijayalakshmi, V. & 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 Edition. Pearson Education, New York.