

**PENERAPAN METODE *BACKPROPAGATION NEURAL NETWORK*
(BNN) UNTUK MEMPREDIKSI HARGA MINYAK DUNIA**

(Skripsi)

Oleh

DINDA AYU RACHMADINA



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRACT

IMPLEMENTATION OF BACKPROPAGATION NEURAL NETWORK (BNN) METHOD TO PREDICT WORLD OIL PRICES

By

DINDA AYU RACHMADINA

Artificial Neural Network (ANN) is an information processing system that has the same characteristics as the workings of the human biological nervous system. One of them ANN that is often used in carrying out predictive analysis or forecasting time series data is the Backpropagation Neural Network (BNN) algorithm. BNN is a gradient drop method to minimize errors that have two calculation stages. Using the BNN method can be trained to analyze past data patterns with the desired output at the present moment. In this research, BNN method is used to see the distribution of past data which will then be used to see world oil prices based on the distribution of data in past data patterns. Based on the result obtained, it appears that the BNN method has quite good performance for analyzing world oil price data. This is indicated by the MSE value obtained at 0.019.

Keywords: *artificial neural network, backpropagation, oil prices*

ABSTRAK

PENERAPAN METODE *BACKPROPAGATION NEURAL NETWORK* (BNN) UNTUK MEMPREDIKSI HARGA MIYAK DUNIA

Oleh

DINDA AYU RACHMADINA

Jarigan Syaraf Tiruan (JST) merupakan sistem pemrosesan informasi yang memiliki karakteristik sama dengan cara kerja sistem saraf biologis manusia. Salah satu JST yang sering digunakan dalam melakukan analisis prediksi atau peramalan data runtun waktu yaitu algoritma *Backpropagation Neural Network* (BNN). BNN adalah metode penurunan gradien untuk meminimalkan galat yang memiliki dua tahap perhitungan. Dengan menggunakan metode BNN dapat dilatih untuk menganalisa pola data masa lalu dengan *output* yang diinginkan saat ini. Pada penelitian ini, metode BNN digunakan untuk melihat sebaran data masa lalu yang selanjutnya akan digunakan untuk melihat harga minyak dunia berdasarkan sebaran data pada pola data masa lalu. Berdasarkan hasil yang didapatkan, terlihat bahwa metode BNN memiliki peforma yang cukup baik untuk menganalisis data harga minyak dunia. Ditandai dengan adanya nilai MSE yang didapat sebesar 0.019.

Kata kunci: *jaringan syaraf tiruan, backpropagation, harga minyak*

**PENERAPAN METODE *BACKPROPAGATION NEURAL NETWORK*
(BNN) UNTUK MEMPREDIKSI HARGA MINYAK DUNIA**

Oleh

DINDA AYU RACHMADINA

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
2024**

Judul Skripsi : **PENERAPAN METODE
BACKPROPAGATION NEURAL NETWORK
(BNN) UNTUK MEMPREDIKSI HARGA
MINYA DUNIA**

Nama Mahasiswa : **Dinda Ayu Rachmadina**

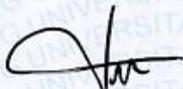
Nomor Pokok Mahasiswa : **1917031072**

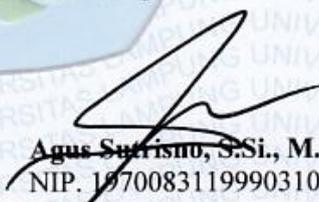
Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

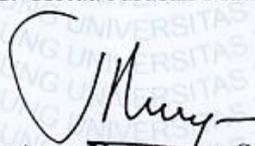


1. Komisi Pembimbing


Drs. Nusyirwan, M.Si.
NIP. 199610101992031028


Agus Sutrisno, S.Si., M.Si.
NIP. 197008311999031002

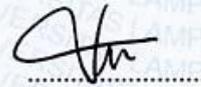
2. Ketua Jurusan Matematika


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

MENGESAHKAN

1. Tim Penguji

Ketua : **Dr. Nusyirwan, M.Si.**



Sekretaris : **Agus Sutrisno, S.Si., M.Si.**



Penguji
Bukan Pembimbing : **Prof. Ir. Netti Herawati, M.Sc., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi: **19 Januari 2024**

PERNYATAAN

Yang bertanda tangan di bawah ini:

Nama : **Dinda Ayu Rachmadina**
Nomor Pokok Mahasiswa : **1917031072**
Jurusan : **Matematika**
Judul Skripsi : **Penerapan Metode Backpropagation Neural Network (BNN) untuk Memprediksi Harga Minyak Dunia**

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

Bandar Lampung, 19 Januari 2024
Yang Menyatakan,



Dinda Ayu Rachmadina
NPM. 1917031072

RIWAYAT HIDUP

Penulis bernama lengkap Dinda Ayu Rachmadina, anak kedua dari lima bersaudara yang dilahirkan di Bandar Lampung pada tanggal 30 November 2000 oleh pasangan Bapak Eko Sunu Sutrisno, S.E. dan Ibu Agus Sriyanti, S.Pd.

Penulis menempuh pendidikan di TK Transmigrasi yang diselesaikan pada tahun 2007, kemudian melanjutkan sekolah di SD Negeri 3 Labuhan Ratu yang diselesaikan pada tahun 2013, kemudian melanjutkan sekolah di SMP Negeri 22 Bandar Lampung, dan kemudian melanjutkan sekolah di SMA Negeri 7 Bandar Lampung yang diselesaikan pada tahun 2019.

Pada tahun 2019, penulis terdaftar sebagai Mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis pernah bergabung menjadi Anggota Bidang Minat dan Bakat Himpunan Jurusan Matematika (HIMATIKA) 2020.

Pada tahun 2022, penulis melaksanakan Kerja Praktik (KP) di Kantor Witel Lampung selama 40 hari di bulan Januari hingga Februari. Lalu penulis juga melaksanakan Kuliah Kerja Nyata (KKN) selama 40 hari dari bulan Juni hingga Agustus di Desa Nibung, Kecamatan Gunung Pelindung, Kabupaten Lampung Timur.

KATA INSPIRASI

“Allah tidak akan membebani hamba-Nya di luar batas kemampuannya”

(Q.S. Al-Baqarah: 286)

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan”

(Q.S. Al-Insyirah: 5-6)

“Soon you’ll understand why your timing is perfect and why things had to happen the way it did to guide you to where you were meant to be”

(Idil Ahmed)

PERSEMBAHAN

Puji dan syukur kepada Allah Subhanahuwata'ala, atas segala limpah rahmat, berkah, ridho serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik. Karya sederhana ini kupersembahkan kepada:

Ibu dan Bapak

Sebagai tanda terimakasih atas segala perjuangan dan pengorbanan yang telah diberikan. Tak luput pula doa, ridha, dan dukungan yang senantiasa kalian berikan hingga penulis bisa berada di titik ini.

Almamater tercinta, Universitas Lampung

SANWACANA

Puji syukur atas kehadiran Allah SWT., yang telah memberikan rahmat, dan ridhanya sehingga penulis mampu menyelesaikan skripsi yang berjudul “ Penerapan Metode *Backpropagation Neural Network (BNN)* untuk Memprediksi Harga Minyak Dunia”. Skripsi ini disusun sebagai salah satu syarat untuk mendapatkan gelar Sarjana Matematika pada Jurusan Matematika FMIPA Unila.

Dalam penyelesaian skripsi ini, penulis menyadari adanya keterbatasan pengetahuan dan kemampuan yang dimiliki, sehingga penulis mendapatkan banyak bimbingan, arahan, dan bantuan dari berbagai pihak. Oleh karena itu, pada kesempatan ini, penulis ingin menyampaikan terima kasih sebanyak-banyaknya kepada:

1. Bapak Drs. Nusyirwan, M.Si., selaku dosen Pembimbing I sekaligus dosen Pembimbing Akademik yang selalu bersedia memberikan kesediaan waktu, arahan, bimbingan, dan dukungan yang membangun dalam proses penyusunan skripsi ini maupun selama penulis menjalani perkuliahan.
2. Bapak Pandri Ferdias, S.Si., M.Sc., selaku dosen Pembimbing II dari awal sampai seminar proposal yang telah memberikan waktu, arahan, bimbingan, dan dukungan yang membangun dalam proses penyusunan skripsi ini.
3. Bapak Agus Sutrisno, S.Si., M.Si., selaku Pembimbing II dari seminar hasil sampai akhir yang juga telah memberikan waktu, arahan, bimbingan, dan dukungan yang membangun dalam proses penyusunan skripsi ini.
4. Ibu Prof. Ir. Netti Herawati, M.Sc., Ph.D. selaku dosen Pembahas yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat lebih baik lagi.

5. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Kepala Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh dosen, staf, dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Orang tuaku tersayang, Bapak dan Ibu yang selalu memberikan semangat, dukungan, serta doa kepada penulis. Terimakasih atas segala perjuangan dan pengorbanan sehingga penulis bisa berada di titik ini. Semoga penulis dapat memberikan kebahagiaan dan selalu menjadi kebanggaan Ibu dan Bapak.
9. Eyang, Om, Tante, Mas Bagus, Aini, Annisa, dan Fatih yang selalu memberika dukungan, doa, dan semangat, serta senantiasa menjadi teman cerita penulis di kala penulis merasa kesulitan.
10. Sahabat-sahabat seperjuangan, Citra, Grace, Nabilla, Dilla, Putri, dan Zidny, yang selalu ada sejak awal sampai akhir perkuliahan. Terimakasih atas bantuan, semangat, canda, dan tawa selama masa perkuliahan.
11. Teman-teman mahasiswa Jurusan Matematika angkatan 2019.
12. Seluruh pihak yang telah membantu penulis dalam pengerjaan skripsi ini yang tidak bisa disebutkan satu persatu.

Penulis menyadari ketidaksempurnaannya skripsi ini di mana masih banyak kekurangan dalam penyajian maupun teknik penulisan. Oleh karena itu, saran dan kritik yang membangun senantiasa penulis harapkan dari seluruh pihak. Penulis berharap semoga skripsi ini dapat memberikan manfaat bagi pembaca dan penulis sendiri.

Bandar Lampung, 19 Januari 2024
Penulis,

Dinda Ayu Rachmadina

DAFTAR ISI

| | Halaman |
|---|---------|
| DAFTAR TABEL | vi |
| DAFTAR GAMBAR | vii |
| I. PENDAHULUAN | 1 |
| 1.1 Latar Belakang dan Masalah | 1 |
| 1.2 Tujuan Penelitian..... | 3 |
| 1.3 Manfaat Penelitian..... | 4 |
| II. TINJAUAN PUSTAKA | 5 |
| 2.1 Data Deret Waktu | 5 |
| 2.1.1 Pola Data Deret Waktu | 5 |
| 2.1.2 Autokorelasi..... | 6 |
| 2.2 Prediksi | 9 |
| 2.3 Pembagian Data..... | 10 |
| 2.3.1 Data <i>Training</i> | 10 |
| 2.3.2 Data <i>Testing</i> | 10 |
| 2.4 Normalisasi Data | 11 |
| 2.5 <i>Machine Learning</i> | 12 |
| 2.6 <i>Artificial Neural Network</i> (ANN)..... | 13 |
| 2.7 <i>Backpropagation Neural Network</i> | 14 |
| 2.8 Fungsi Aktivasi..... | 19 |
| 2.9 Denormalisasi | 21 |
| 2.10 Ketepatan Model | 21 |
| 2.11 Minyak..... | 23 |

| | |
|--|----|
| III. METODOLOGI PENELITIAN | 24 |
| 3.1 Waktu dan Tempat Penelitian | 24 |
| 3.2 Data Penelitian | 24 |
| 3.3 Metode Penelitian..... | 25 |
| IV. HASIL DAN PEMBAHASAN | 26 |
| 4.1 Statistika Deskriptip | 26 |
| 4.2 Menentukan Input Jaringan Berdasarkan <i>Lag</i> yang Signifikan | 27 |
| 4.3 Melakukan Normalisasi Data | 29 |
| 4.4 Pembagian Data..... | 30 |
| 4.5 Fungsi Aktivasi..... | 30 |
| 4.6 Proses Pelatihan dan Pengujian | 30 |
| 4.6.1 Proses Pelatihan | 31 |
| 4.6.2 Proses Pengujian | 31 |
| 4.7 Denormalisasi Data | 32 |
| 4.8 Visualisasi Hasil | 33 |
| V. KESIMPULAN | 35 |
| DAFTAR PUSTAKA | 36 |
| LAMPIRAN | 39 |

DAFTAR TABEL

| Tabel | Halaman |
|--|---------|
| 1. Simbol-simbol algoritma <i>Backpropagation</i> | 19 |
| 2. Karakteristik data harga mingguan minyak dunia | 27 |
| 3. Data input jaringan | 28 |
| 4. Normalisasi data | 29 |
| 5. Pembagian data <i>training</i> dan <i>testing</i> | 30 |
| 6. Hasil evaluasi..... | 32 |
| 7. Denormalisasi data..... | 33 |
| 8. Perbandingan data aktual dan data hasil prediksi | 34 |

DAFTAR GAMBAR

| Gambar | Halaman |
|---|---------|
| 1. Plot data deret waktu | 6 |
| 2. Plot <i>Autocorrelation Function</i> (ACF) | 8 |
| 3. Plot <i>Partial Autocorrelation Function</i> (PACF)..... | 8 |
| 4. Arsitektur jaringan syaraf tiruan (JST)..... | 13 |
| 5. Arsitektur <i>Backpropagation Neural Network</i> (BNN) | 15 |
| 6. Fungsi aktivasi <i>Sigmoid Biner</i> | 20 |
| 7. Fungsi aktivasi <i>Tanh</i> | 21 |
| 8. Plot data harga mingguan minyak dunia | 26 |
| 9. Plot data minyak dunia <i>Autocorrelation Function</i> (ACF)..... | 27 |
| 10. Plot data minyak dunia <i>Partial Autocorrelation Function</i> (PACF) | 28 |
| 11. Plot prediksi harga minyak dunia | 33 |

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Perkembangan teknologi dari hari kehari semakin canggih dan berkembang secara pesat. Perkembangan pada saat ini cenderung untuk mengembangkan teknologi yang cerdas dengan memiliki kemampuan untuk berpikir dan mengambil keputusan layaknya manusia. Para ahli mencoba untuk mengadaptasi otak manusia ke dalam sistem komputer sehingga diharapkan di masa yang akan datang kecerdasan tersebut dapat mendekati kerja otak manusia. Penerapan kecerdasan buatan yang sering diaplikasikan dalam berbagai persoalan dikehidupan salah satunya adalah jaringan syaraf tiruan.

Artificial Neural Network (ANN) atau biasa disebut Jaringan Syaraf Tiruan (JTS) adalah sistem komputasi arsitektur yang operasinya merupakan sistem pemrosesan informasi dalam menstimulasikan sistem kecerdasan buatan yang memiliki karakteristik sama dengan cara kerja sistem saraf biologis manusia (Fausett, 1994). ANN terdiri atas kumpulan neuron yang tersusun dalam beberapa lapisan yaitu lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan *output* (*output layer*). Dalam penerapannya, analisis ANN sering digunakan dalam prediksi atau peramalan suatu data runtun waktu.

Prediksi merupakan hasil dari kegiatan memprediksi atau memperkirakan nilai pada masa yang akan datang dengan menggunakan data masa lalu. Prediksi tidak selalu memberikan jawaban yang pasti, melainkan berusaha untuk memberikan jawaban sedekat mungkin dengan kejadian (Herjanto, 2006). Prediksi bertujuan untuk mengenali pola sistematis serta menemukan pola hubungan kecenderungan yang didasarkan pada data historis. Pengumpulan data historis berperan sebagai tahapan pertama yang dilakukan untuk sebuah prediksi (Makridakis, dkk., 2006). Salah satu analisis prediksi atau peramalan sering digunakan dalam ANN adalah algoritma *Backpropagation Neural Network*.

Backpropagation adalah sebuah metode sistematis jaringan syaraf tiruan yang menggunakan algoritma pembelajaran terawasi (*supervised learning*) dan biasanya digunakan oleh *perceptron* dengan banyak layar lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyi (Astuti, 2009). Pada jaringan ini diberikan sepasang pola yang terdiri atas pola masukan dan pola yang diinginkan. Ketika suatu pola diberikan kepada jaringan, bobot-bobot diubah untuk memperkecil perbedaan pola keluaran dan pola yang diinginkan yang disebut galat. Pada algoritma *Backpropagation* dilakukan latihan berulang-ulang sehingga mendapatkan galat terkecil dan mendapatkan pola yang diinginkan. Algoritma *Backpropagation Neural Network* menggunakan galat pada nilai keluaran untuk mengganti nilai bobot-bobotnya pada arah mundur. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi terbaik berdasarkan tingkat akurasi model. Fungsi aktivasi digunakan untuk menentukan keluaran suatu neuron (Siang, 2005).

Beberapa penelitian yang pernah dilakukan sebelumnya menggunakan ANN algoritma *backpropagation* antara lain: pada penelitian yang dilakukan oleh Herawati, N., dkk. (2022) mengenai perbandingan metode Chen *fuzzy time series* dan BNN dalam memprediksi indeks harga saham gabungan, dimana dari analisis diperoleh hasil bahwa metode BNN lebih baik dibandingkan metode Chen *fuzzy time series*. Pada penelitian Nguyen, Ly, & Pham (2020) mengenai prediksi sudut pergeseran tanah dengan menggunakan model dasar *machine learning* yaitu BNN

yang memiliki hasil prediksi terbaik dengan nilai galat sebesar 0.0328. Pada penelitian Untoro (2020) dalam memprediksi harga saham menggunakan ANN memberikan hasil yang maksimal dalam melakukan prediksi dengan presentase nilai galat yang relatif rendah. Kemudian pada penelitian Siregar &Wanto (2017) dalam memprediksi indeks pembangunan manusia menggunakan algoritma *backpropagation* didapatkan struktur terbaik model yaitu 3-48-1 dengan tingkat akurasi 100% dan nilai galat sebesar 0,00063. Hal ini menandakan bahwa algoritma *backpropagation* cukup baik ketika digunakan untuk memprediksi data.

Minyak mentah atau *crude oil* merupakan salah satu sumber daya yang sangat penting saat ini, dikarenakan hasil olahan minyak mentah merupakan sumber energi. Sedangkan permintaan masyarakat akan minyak bumi selalu meningkat untuk memenuhi kebutuhan sehari-hari. Hal tersebut menyebabkan kapasitas minyak semakin hari semakin berkurang. Jika konsumsi terhadap minyak terus-menerus meningkat tetapi tidak diimbangi dengan ketersediaan minyak yang ada maka akan terjadilah kelangkaan sumber daya minyak. Dampak yang telah terjadi dari ketidakseimbangan antara produksi dan konsumsi minyak saat ini salah satunya adalah kenaikan harga minyak yang berfluktuatif (Fauzanissa, dkk., 2016). Prediksi harga minyak memberikan gambaran bagaimana keadaan ketersediaan minyak pada masa mendatang. Selain itu, harga minyak harus diketahui secara spesifik karena sangat berpengaruh terhadap perekonomian. Oleh karena itu, penelitian ini akan memprediksi harga minyak dunia dengan menerapkan metode *Backpropagation Neural Network* (BNN).

1.2 Tujuan Penelitian

Adapun tujuan sebagai berikut:

1. Mengimplementasikan *Backpropagation Neural Network* (BNN) dalam menganalisis harga minyak dunia.

2. Mengetahui performa metode *Backpropagation Neural Network* (BNN) dalam menganalisis harga minyak dunia.

1.3 Manfaat Penelitian

Adapun manfaat yang dapat diambil dari penelitian ini adalah:

1. Sebagai rujukan pengembangan ilmu matematika tentang analisis *Backpropagation Neural Network* (BNN).
2. Dapat menjadi bahan pertimbangan dan informasi tambahan bagi pembaca apabila ingin melakukan penelitian lanjut terkait hasil analisis yang didapatkan.

II. TINJAUAN PUSTAKA

2.1 Data Deret Waktu

Data deret waktu merupakan analisis peramalan atau prediksi menggunakan hubungan antar variabel yang diperkirakan dengan deret waktu. Runtun waktu adalah pengamatan pada suatu variabel dari waktu lampau dan dicatat secara berurutan menurut urutan waktu dengan periode yang tetap (Hanke & Weiher, 2004). Data deret waktu merupakan rangkaian pengamatan yang berurutan terhadap suatu variabel berdasarkan waktu dengan interval waktu yang tetap (Wei, 2006).

2.1.1 Pola Data Deret Waktu

Pola data dibagi menjadi 4 yaitu horizontal, musiman, siklis, dan tren dengan masing-masing pola data memiliki kriteria yang berbeda-beda (Aden, 2020). Langkah penting yang harus dilakukan dalam memilih metode pada peramalan yang tepat yaitu mempertimbangkan jenis pola data, sehingga metode peramalan yang paling sesuai dengan pola data tersebut dapat diterapkan. Berikut adalah pola data deret waktu:

a. Horizontal

Pola data horizontal merupakan fluktuasi data yang relative konstan walaupun mengalami kenaikan atau penurunan. Contohnya pada data penjualan produk yang tidak meningkat dan menurun selama waktu tertentu.

b. Musiman

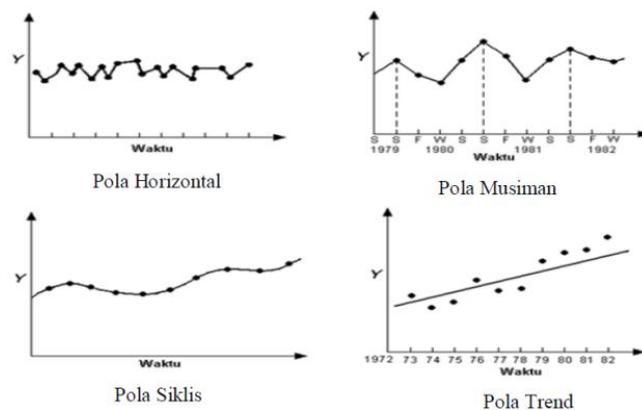
Pola data musiman terjadi jika suatu deret data yang dipengaruhi oleh faktor musiman. Pola data musiman merupakan fluktuasi data yang berulang setiap beberapa periode tertentu, seperti hari, minggu bahkan bulan.

c. Siklis

Pola data siklis dipengaruhi oleh fluktuasi dalam jangka panjang. Contohnya pada data penjualan produk utama selama beberapa tahun, produk utamanya seperti mobil dan baja.

d. Tren

Pola data tren merupakan kenaikan atau penurunan data yang terjadi dalam waktu yang lama.



Gambar 1. Pola Data Deret Waktu

2.1.2 Autokorelasi

Definisi autokorelasi adalah terjadinya korelasi antar data di dalam data deret waktu yang dipisahkan dalam *lag* (selang waktu). Artinya, jika $lag = 2$, maka nilai t akan dikorelasikan dengan $t + 2$ (data pertama akan dikorelasikan dengan data ketiga), jika menggunakan $lag = 4$, maka nilai t akan dikorelasikan dengan $t + 4$ (data pertama akan dikorelasikan dengan data kelima), dan begitu

seterusnya. Hal ini biasanya ditulis dengan rumus korelasi (X_t, X_{t+k}) dengan k adalah jumlah *lag* dan t adalah nilainya. Untuk mendefinisikan autokorelasi diperlukan definisi autokovarians. Autokovarians dan autokorelasi antara X_t dan X_{t+k} berturut-turut dapat didefinisikan sebagai berikut (Wei, 2006):

$$\gamma_k = Cov(X_t, X_{t+k}) = E[(X_t - \mu)(X_{t+k} - \mu)] \quad (2.1)$$

dan

$$\rho_k = r_k \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)}\sqrt{Var(X_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.2)$$

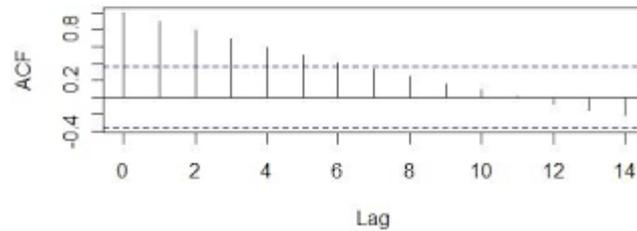
dengan:

- ρ_k = autokorelasi pada *lag-k*
- γ_k = autokovarians pada *lag- k*
- t = waktu pengamatan, $t = 1,2,3, \dots$
- X_t = pengamatan pada waktu ke- t
- X_{t+k} = pengamatan pada waktu ke- $t + k$.

Dimana $Var(X_t) = Var(X_{t+k}) = \gamma_0$ dan $\rho_0 = 1$. Sebagai fungsi dari k , γ_k disebut fungsi autokovarianas dan ρ_k disebut sebagai fungsi autokorelasi, yang mewakili kovarians dan korelasi antara X_t dan X_{t+k} dari proses yang sama, hanya dipisahkan oleh *lag-k*. Jika X_t dan X_{t+k} independen maka $\gamma_k = Cov(X_t, X_{t+k}) = 0$ tetapi tidak berlaku sebaliknya. X_t dan X_{t+k} dikatakan tidak berkorelasi jika $\rho_k = 0$. Hubungan negatif sempurna dengan dua variabel memiliki koefisien korelasi sebesar -1 dan hubungan positif sempurna dengan dua variabel memiliki koefisien korelasi sebesar +1. Dengan demikian, koefisien korelasi bervariasi antara -1 dan +1 (Hanke & Winchern, 2004).

Fungsi autokorelasi atau *Autocorrelation Function* (ACF) merupakan suatu fungsi yang menunjukkan besarnya korelasi atau hubungan linear antara pengamatan

pada waktu t saat sekarang dengan pengamatan pada waktu-waktu sebelumnya ($t - 1, t - 2, \dots, t - k$).

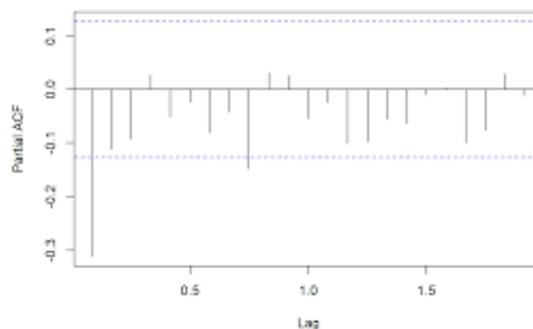


Gambar 2. Plot *Autocorrelation Function* (ACF).

Pada Gambar 2 menunjukkan plot fungsi autokorelasi pada data deret waktu dimana *lag* yang keluar dari batas (daerah interval) menunjukkan autokorelasi signifikan. Pola dari koefisien autokorelasi sering digunakan untuk menetapkan ada atau tidaknya faktor musiman di dalam data deret waktu dan menentukan order model data deret waktu yang tepat pada situasi tertentu, serta menentukan kestasioneran data. Rumus perhitungan fungsi autokorelasi sebagai berikut (Machmudin & Ulama, 2012):

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 0, 1, 2, \dots \quad (2.3)$$

dengan nilai rata-rata dari deret waktu ($\bar{Z} = \sum_{t=1}^n \frac{Z_t}{n}$) dapat didefinisikan \bar{Z} .



Gambar 3. Plot *Partial Autocorrelation Function* (PACF).

Pada Gambar 3 menunjukkan plot fungsi autokorelasi parsial atau *Partial Autocorrelation Function* (PACF). Fungsi autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara X_t dan X_{t+k} , apabila pengaruh dari lag 1, 2, 3, . . . , dan seterusnya sampai $k - 1$ dianggap terpisah. Pada PACF, pengawalan perhitungan nilai dimulai dengan $\widehat{\phi}_{kk} = \widehat{\rho}_1$, dimana $\widehat{\rho}_1$ nilai dari autokorelasi lag pertama. Berikut ini adalah persamaan untuk menghitung nilai fungsi autokorelasi parsial lag- k (Machmudin & Ulama, 2012):

$$\widehat{\phi}_{kk} = \frac{\widehat{\rho}_1 \sum_{j=1}^{k-1} \phi_{k-1j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1j} \rho_{k-j}} \quad (2.4)$$

dengan:

$\widehat{\phi}_{kk}$ = nilai PACF pada lag ke- k

ρ_k = nilai ACF pada lag ke- k .

2.2 Prediksi

Prediksi adalah perpaduan antara seni dan ilmu dalam memperkirakan keadaan di masa yang akan datang, dengan memproyeksikan data-data masa lampau ke masa yang akan datang dengan menggunakan model matematika maupun perkiraan yang subjektif (Montgomery, 1990). Prediksi tidak selalu memberikan jawaban yang pasti, melainkan berusaha untuk memberikan jawaban sedekat mungkin dengan kejadian (Herjanto, 2006). Prediksi bertujuan untuk mengenali pola sistematis serta menemukan pola hubungan kecenderungan yang didasarkan pada data historis. Pengumpulan data historis berperan sebagai tahapan pertama yang dilakukan untuk sebuah prediksi (Makridakis, dkk., 2006).

2.3 Pembagian Data

Sekumpulan data yang digunakan dalam jaringan syaraf tiruan dapat disebut data set, kemudian data tersebut dibagi menjadi dua bagian yaitu *training* dataset dan *testing* dataset. Beberapa proporsi pembagian data yang pada pembagian datanya berfungsi untuk mencari pembagian data terbaik yaitu dengan menggunakan 70:30, 80:20, dan 90:10 (Utami & Ulama, 2015).

2.3.1 Data Training

Data *training* adalah data penelitian yang dapat digunakan untuk melatih algoritma dan juga mencari model yang cocok. Proses ini dimulai dengan memasukkan data latih ke dalam jaringan (Warsito, 2009). Dengan menggunakan data latih, jaringan mengubah bobot menjadi penghubung antara neuron-neuron. Tahapan ini berlangsung pada beberapa iterasi dan berhenti setelah menemukan bobot yang sesuai dimana nilai galat yang diinginkan telah tercapai atau jumlah iterasi telah mencapai nilai maksimal yang ditetapkan.

2.3.2 Data Testing

Data *testing* adalah bagian dari dataset yang kita uji untuk melihat keakuratannya atau performanya. Data pengujian ini hanya mencakup data masukan, bukan data keluaran yang diharapkan. Data pengujian digunakan untuk menilai seberapa baik algoritma yang dilatih dan memperkirakan model untuk prediksi data deret waktu. Pada proses *testing*, algoritma diuji dengan menggunakan data *testing* dan data *training* yang merupakan dua data berbeda. Pengujian dilakukan dengan memasukan suatu pola yang belum pernah dilatih sebelumnya (data uji) dengan menggunakan bobot hasil tahap pelatihan. Diharapkan bobot-bobot hasil

pelatihan yang telah menghasilkan galat minimal juga menghasilkan galat minimal pada tahap pengujian (Warsito, 2009). Data *training* digunakan dalam proses pembentukan arsitektur terbaik dalam proses pelatihan, sedangkan data *testing* digunakan dalam pengujian keakuratan dari arsitektur yang telah terbentuk.

2.4 Normalisasi Data

Normalisasi data adalah mentransformasi data ke dalam *range* 0 dan 1. Tujuan dari normalisasi data adalah untuk menghilangkan kerangkapan data, merubah nilai menjadi satu satuan, dan mempermudah pemodifikasian data. Transformasi data dengan normalisasi dapat dilakukan dengan berbagai cara, salah satunya yaitu *min-max normalization*. *Min-max Normalization* merupakan metode normalisasi dengan melakukan transformasi linear terhadap data asli sehingga menghasilkan keseimbangan nilai perbandingan antar data saat sebelum dan sesudah proses (Hanifah, dkk., 2017). Metode ini dapat menggunakan rumus sebagai berikut:

$$x_i' = \frac{x_i - x_{min}}{X_{max} - x_{min}} \quad (2.5)$$

dengan:

x_i' = data hasil normalisasi

x_i = data sebelum normalisasi

x_{min} = nilai minimum dari data sebelum dinormalisasi.

x_{max} = nilai maksimum dari data sebelum dinormalisasi.

2.5 Machine Learning

Machine learning atau pembelajaran mesin merupakan cabang ilmu dari kecerdasan buatan (*artificial intelligence*), dengan pemrograman untuk memungkinkan komputer menjadi cerdas berperilaku seperti manusia dan meningkatkan pemahamannya melalui pengalaman secara otomatis (Kusuma, 2020). Ciri dari *machine learning* adalah adanya proses pelatihan dan pembelajaran. *Machine learning* memungkinkan komputer mempelajari sejumlah data (*learn form data*) sehingga dapat menghasilkan suatu model untuk melakukan proses input-output tanpa menggunakan kode program yang dibuat secara eksplisit. Oleh karena itu, *machine learning* membutuhkan data untuk dipelajari yang disebut sebagai data *training*. Terdapat dua macam tipe pembelajaran dalam metode ini, yaitu:

a. *Supervised Learning* (Pembelajaran Terawasi)

Metode pembelajaran terawasi (*supervised learning*) digunakan ketika nilai *output* yang diinginkan sudah diketahui sebelumnya. Nilai *output* jaringan ini akan dibandingkan dengan nilai *output* target yang dinamakan nilai galat. Ketika nilai galat masih cukup besar artinya masih perlu dilakukan pembelajaran lagi hingga didapatkan nilai galat yang kecil atau nilai *output* dari jaringan yang tidak berbeda jauh dengan nilai *output* target. Contoh algoritma pembelajaran terawasi yaitu *KNN*, *Naive Bayes*, *Decision Trees*, *Regresi linier*, *Support Vector Machine*, *Backpropagation Neural Network*.

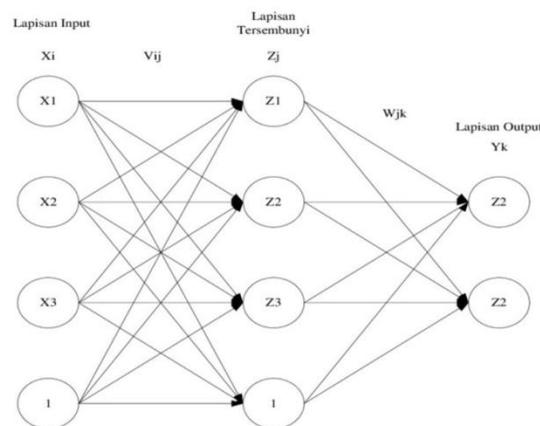
b. *Unsupervised Learning* (Pembelajaran Tidak Terawasi)

Metode pembelajaran tidak terawasi (*unsupervised learning*) merupakan metode pembelajaran ketika tidak memerlukan acuan nilai *output* yang diharapkan. Pada metode ini tidak diketahui seperti apa nilai *output* yang diharapkan, hanya ditentukan nilai bobot dalam suatu *range* sesuai nilai input yang diberikan.

Tujuan utama dari metode ini adalah mengelompokkan (klasifikasi) unit-unit yang memiliki kemiripan di suatu area tertentu. Contoh algoritma pembelajaran tidak terawasi yaitu *Fuzzy C-Means*, *K-Means*, *LVQ (Learning Vector Quantization)*, *Self Organizing Map*.

2.6 Artificial Neural Network (ANN)

Artificial Neural Network (ANN) atau biasa disebut Jaringan Syaraf Tiruan (JST) adalah sistem komputasi arsitektur yang operasinya merupakan system pemrosesan informasi dalam menstimulasikan system kecerdasan buatan yang memiliki karakteristik sama dengan cara kerja system saraf biologis manusia (Fausett, 1994). JST dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi bahwa pada pemrosesan informasi terjadi pada banyak elemen sederhana (neuron). Sinyal dikirimkan di antara neuron-neuron melalui penghubung-penghubung di mana penghubung antar neuron memiliki bobot yang memperkuat atau memperlemah sinyal dan untuk menentukan *output*. Setiap neuron menggunakan fungsi aktivasi yang dikenakan pada jumlahan input yang diterima. Besarnya *output* ini selanjutnya dibandingkan dengan suatu batas ambang.



Gambar 4. Arsitektur Jaringan Syaraf Tiruan (JST).

Jaringan syaraf tiruan yang ditentukan oleh pola hubungan antar neuron (disebut arsitektur jaringan). Jaringan syaraf tiruan menggunakan metode untuk menentukan bobot penghubung (disebut metode *training*) dan fungsi aktivasi (Siang, 2005). Jaringan Saraf Tiruan (JST) dengan layar tunggal memiliki keterbatasan dalam pengenalan pola. Kelemahan ini bisa ditanggulangi dengan menambahkan satu atau beberapa lapisan tersembunyi di antara lapisan masukan

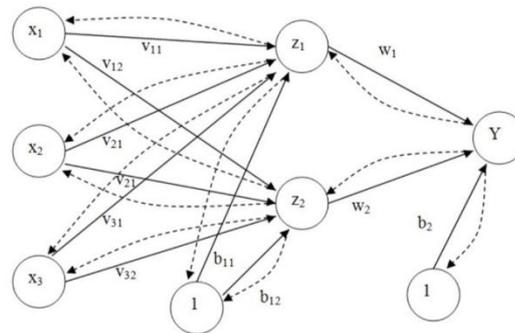
dan keluaran. Meskipun penggunaan lebih dari satu lapisan tersembunyi memiliki kelebihan manfaat untuk beberapa kasus, tapi pelatihannya memerlukan waktu yang lama. Seperti halnya model jaringan syaraf tiruan lainnya, algoritma *Backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan dengan tujuan mengenali pola yang digunakan selama pelatihan serta memberikan respons yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan.

2.7 Backpropagation Neural Network

Backpropagation adalah sebuah metode sistematis jaringan syaraf tiruan yang menggunakan metode pembelajaran terawasi (*supervised learning*) dan banyak lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyi. Metode *backpropagation* pada awalnya dirancang untuk *neural network feedforward*, tetapi pada perkembangannya metode ini diadaptasi untuk pembelajaran pada model *neural network* lainnya (Astuti, 2009). Ciri metode ini adalah meminimalkan nilai galat pada *output* yang dihasilkan oleh jaringan (neuron). Algoritma *backpropagation* mempunyai pengaturan hubungan yang sangat sederhana yaitu jika *output* memberikan hasil yang salah, maka penimbang dikoreksi supaya galat dapat diperkecil dan respon jaringan selanjutnya diharapkan akan mendekati nilai benar. Algoritma ini juga berkemampuan untuk memperbaiki penimbang pada lapisan tersembunyi (*hidden layer*) (Purnomo & Kurniawan, 2006). Lapisan-lapisan penyusun jaringan syaraf tiruan *Backpropagation* dibagi menjadi tiga bagian (Widiastuti, dkk., 2014):

- a. Lapisan input (*input layer*) yaitu neuron di dalam lapisan input yang disebut unit-unit input yang mulai dari lapisan input pertama hingga lapisan input n. Unit-unit input tersebut menerima pola inputan data dari luar yang menggambarkan suatu permasalahan. Semua neuron pada lapisan input ini dapat terhubung ke neuron pada lapisan tersembunyi (*hidden layer*) atau dapat langsung ke lapisan luaran (*output layer*) jika neuron tidak menggunakan lapisan tersembunyi.

- b. Lapisan tersembunyi (*hidden layer*) adalah neuron yang berada di dalam lapisan tersembunyi atau bias disebut unit-unit tersembunyi dimana *output*nya tidak dapat secara langsung diamati
- c. Lapisan *output* (*output layer*) merupakan neuron dalam lapisan *output* disebut unit-unit output. Output dari lapisan ini merupakan solusi jaringan syaraf tiruan terhadap suatu permasalahan.



Gambar 5. Arsitektur *Backpropagation Neural Network*.

Lapisan input dilambangkan dengan X , lapisan tersembunyi dilambangkan dengan Z , dan lapisan *output* dilambangkan dengan Y . Bobot antara X dan Z dilambangkan dengan “ v ” sedangkan bobot antara Z dan Y dilambangkan dengan “ w ”. Algoritma *Backpropagation Neural Network* terdiri dari tiga lapisan, yaitu lapisan input, lapisan tersembunyi dan lapisan *output*. Pada pengambilan input, terlebih dahulu dilakukan inisialisasi bobot, kemudian masuk ke dalam algoritma *Backpropagation* yang terdiri dari komputasi maju yang bertujuan untuk menelusuri besarnya galat dan komputasi balik untuk menyesuaikan bobot. Pelatihan dengan algoritma *Backpropagation* terdiri dua tahap yaitu perambatan maju dan perambatan mundur. Selama perambatan maju, tiap unit masukan (X_i) menerima sebuah masukan sinyal ini dan sinyal ini diteruskan ke tiap-tiap lapisan tersembunyi $Z_1, Z_2, Z_3, \dots, Z_{1p}$. Tiap unit tersembunyi ini kemudian menghitung aktivasinya dan mengirimkan sinyalnya (Z_j) ke tiap lapisan *output*. Unit-unit lapisan keluaran memberikan tanggapan yang disebut sebagai keluaran jaringan dan saat keluaran jaringan berbeda dengan keluaran yang diharapkan maka

keluaran menyebar mundur (*backward*) pada lapisan tersembunyi diteruskan ke unit pada lapisan masukan (Rinjani, dkk., 2019). Oleh karena itu mekanisme pelatihan tersebut dinamakan *Backpropagation*.

Dalam proses pelatihan pada algoritma *Backpropagation* untuk menghitung nilai koreksi bobot diperlukan *learning rate*. Nilai dari *learning rate* ini berada pada *range* 0 sampai dengan 1. Semakin besar nilai *learning rate*, maka ketelitian jaringan semakin berkurang dan semakin kecil nilai *learning rate*, maka ketelitian jaringan semakin besar atau waktu yang diperlukan untuk proses pelatihan semakin lama.

Algoritma *Backpropagation* sering digunakan dalam menyelesaikan masalah peramalan. Hal ini dimungkinkan karena algoritma *Backpropagation* merupakan salah satu jenis pelatihan JST dengan metode pembelajaran terawasi. Pada jaringan ini diberikan sepasang pola yang terdiri atas pola masukan dan pola yang diinginkan. Ketika suatu pola diberikan kepada jaringan, bobot-bobot diubah untuk memperkecil perbedaan pola keluaran dan pola yang diinginkan yang disebut galat. Pada algoritma *Backpropagation* dilakukan latihan berulang-ulang sehingga mendapatkan galat terkecil dan mendapatkan pola yang diinginkan (Nurmila, dkk., 2010).

Backpropagation Neural Network memiliki beberapa langkah yaitu (Siang, 2005):

- a. Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil).
- b. Tetapkan: maksimum *epoch*, target galat, dan *learning rate* (α).
- c. Inisialisasi: $E_{poah} = 0$, $mean\ square\ error = 1$.
- d. Langkah-langkah dalam algoritma pelatihan untuk jaringan *Backpropagation* adalah:
 - Langkah 1 : Menetapkan nilai input.
 - Langkah 2 : Membuat inisialisasi semua bobot dengan bilangan acak kecil.

Fase I : Propogasi Maju (*Forward Propagation*)

Langkah 3 : Tiap unit masukkan $X_i, i = 1,2,3, \dots, p$ menerima sinyal X_i dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya.

Langkah 4 : Tiap-tiap unit lapisan tersembunyi $Z_j, j = 1,2,3, \dots, q$ menjumlahkan sinyal-sinyal *input* terbobot :

$$Z_in_j = V_{0j} + \sum_{i=1}^p X_i V_{ij} \quad (2.7)$$

Kemudian dihitung nilai keluaran dengan menggunakan fungsi aktivasi. Kemudian kirimkan sinyal tersebut ke semua unit di lapisan atasnya.

Langkah 5 : Hasil fungsi tersebut dikirim ke semua unit pada lapisan di atasnya. Tiap-tiap unit keluaran $Y_k, k = 1,2,3, \dots, r$ menjumlahkan sinyal-sinyal *input* terbobot.

$$Y_in_k = W_{0k} + \sum_{j=1}^q Z_j W_{jk} \quad (2.8)$$

Fase II : Propagasi Mundur (*Backpropagation*)

Langkah 6 : Tiap-tiap unit keluaran $Y_k, k = 1,2,3, \dots, r$ menerima target pola yang berhubungan dengan pola input pembelajaran, hitung informasi galat.

$$\begin{aligned} \delta_k &= (t_k - Y_k) f'(Y_in_k) \\ &= (t_k - Y_k) y_k (1 - Z_k) \end{aligned} \quad (2.9)$$

Kemudian hitung koneksi nilai bobot yang kemudian digunakan untuk memperbaharui nilai W_{jk} :

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (2.10)$$

Hitung koreksi nilai bias yang kemudian digunakan untuk memperbaharui nilai W_{0k} :

$$\Delta W_{0k} = \alpha \delta_k \quad (2.11)$$

Kirimkan δ_k ke unit-unit yang ada dilapisan bawahnya.

Langkah 7 : Tiap-tiap unit *hidden* $Z_j (j = 1,2,3, \dots, q)$ menjumlahkan delta input (dari unit-unit yang berada pada lapisan

diatasnya):

$$\delta_j = \sum_{k=1}^r \delta_k W_{jk} f'(Z_{in_j}) \quad (2.12)$$

Kemudian nilai tersebut dikalikan dengan nilai turunan dari fungsi aktivasi untuk menghitung informasi kesalahan.

Hitung koreksi nilai bobot yang kemudian digunakan untuk memperbaharui V_{ij} :

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (2.13)$$

Hitung juga koreksi bias (yang nantinya digunakan untuk memperbaiki nilai V_{0j}):

$$\Delta V_{0j} = \alpha \delta_j \quad (2.14)$$

Fase III : Perubahan Bobot

Langkah 8 : Tiap-tiap unit *output* $Y_k (k = 1, 2, 3, \dots, r)$ memperbaiki bias dan bobotnya ($j = 1, 2, 3, \dots, q$):

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (2.15)$$

$$W_{0k}(\text{baru}) = W_{0k}(\text{lama}) + \Delta W_{0k} \quad (2.16)$$

Tiap-tiap unit *hidden* $Y_j (j = 1, 2, 3, \dots, q)$ memperbaiki bias dan bobotnya ($i = 1, 2, 3, \dots, p$):

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (2.17)$$

$$V_{0j}(\text{baru}) = V_{0j}(\text{lama}) + \Delta V_{0j} \quad (2.18)$$

Langkah 9 : Menghitung galat, jika nilai galat belum lebih kecil dari pada target galat, maka langkah 2-8 terus dilakukan.

Langkah 10 : Jika telah terpenuhi, maka pelatihan jaringan dapat dihentikan.

Tabel 1. Simbol-Simbol Algoritma *Backpropagation*

| No. | Simbol | Keterangan |
|-----|------------|--|
| 1 | i | Jumlah neuron pada <i>input layer</i> |
| 2 | j | Jumlah neuron pada <i>hidden layer</i> |
| 3 | k | Jumlah neuron pada <i>output layer</i> |
| 4 | X_i | Nilai masukan ke- i pada <i>input layer</i> ($i = 1,2,3, \dots, p$) |
| 5 | Y_k | Nilai aktivasi neuron ke- k tahap umpan maju pada <i>output layer</i> |
| 6 | Z_j | Nilai aktivasi neuron ke- j tahap umpan maju pada <i>hidden layer</i> |
| 7 | Y_{in_k} | Hasil penjumlahan sinyal masukan neuron ke- k pada <i>output layer</i> |
| 8 | Z_{in_j} | Hasil penjumlahan sinyal masukan neuron ke- j pada <i>hidden layer</i> |
| 9 | V_{0j} | Nilai bobot antara neuron ke- i pada <i>input layer</i> dan neuron ke- j pada <i>hidden layer</i> |
| 10 | W_{0k} | Nilai bobot antara neuron ke- j pada <i>hidden layer</i> dan neuron ke- k pada <i>output layer</i> |
| 11 | V_{ij} | Nilai bias neuron ke- j pada <i>hidden layer</i> |
| 12 | W_{jk} | Nilai bias neuron ke- k pada <i>output layer</i> |
| 13 | t_k | Nilai target neuron ke- k pada <i>output layer</i> |
| 14 | δ_j | Nilai <i>gradient descent</i> neuron ke- j pada <i>hidden layer</i> |
| 15 | δ_k | Nilai <i>gradient descent</i> neuron ke- k pada <i>output layer</i> |
| 16 | α | Nilai <i>learning rate</i> |

2.8 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi matematis yang digunakan untuk mendapatkan nilai *output* berdasarkan nilai input dan mengaktifkan atau tidak mengaktifkan

neuron. Informasi yang diproses yaitu melalui fungsi aktivasi dan hasil dari proses ini didistribusikan ke neuron di lapisan berikutnya. Syarat fungsi aktivasi dalam *Backpropagation* bersifat kontinu, terdiferensial dengan mudah dan merupakan fungsi yang tidak turun (Siang, 2005). Terdapat beberapa fungsi aktivasi yang sering digunakan dalam jaringan syaraf tiruan, yaitu:

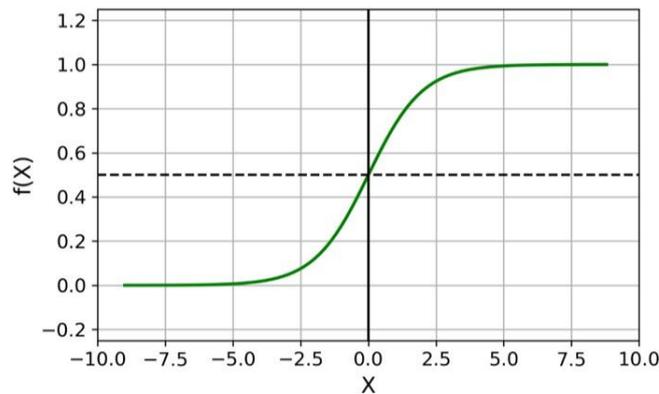
a. Fungsi Aktivasi *Sigmoid Biner*

Fungsi aktivasi *sigmoid biner* digunakan untuk jaringan syaraf tiruan yang dilatih dengan menggunakan metode *backpropagation*. Fungsi ini menghasilkan nilai *output* yang terletak pada interval 0 sampai 1. Fungsi ini dirumuskan sebagai berikut:

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2.19)$$

dengan turunan

$$f'(x) = f(x)[1 - f(x)] \quad (2.20)$$



Gambar 6. Fungsi Aktivasi *Sigmoid Biner*.

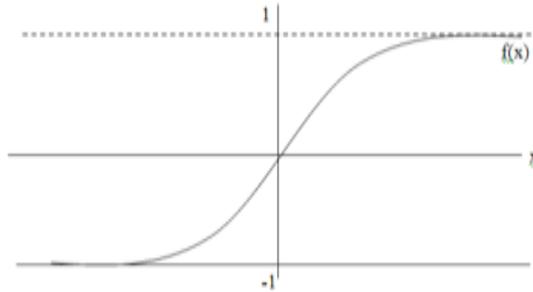
b. Fungsi Aktivasi *Tanh*

Fungsi aktivasi *tanh* merupakan fungsi yang biasa disebut dengan fungsi aktivasi *sigmoid bipolar* dan memiliki nilai *output* yang terletak pada interval -1 sampai 1. Rentang nilai dari fungsi aktivasi *tanh* lebih luas dari fungsi aktivasi *sigmoid biner*. Fungsi aktivasi *tanh* dirumuskan sebagai berikut:

$$y = f(x) = \frac{2}{1 + e^{-x}} - 1 \quad (2.21)$$

dengan turunan

$$f'(x) = \frac{[1 + f(x)][1 - f(x)]}{2} \quad (2.22)$$



Gambar 7. Fungsi Aktivasi *Tanh*.

2.9 Denormalisasi

Denormalisasi merupakan proses yang dapat memberikan atau mengembalikan data ke bentuk data semula, sehingga didapatkan hasil peramalan dari data *training* (Hidayat & Suprpto, 2012). Adapun rumus denormalisasi dalam *range* $[0, 1]$ sebagai berikut:

$$x_i = y_t(x_{max} - x_{min}) + x_{min} \quad (2.23)$$

dengan:

x_i = nilai data yang telah di denormalisasi

y_t = hasil output jaringan ke- t

x_{max} = data dengan nilai maksimum

x_{min} = data dengan nilai minimum.

2.10 Ketepatan Model

Ketepatan model adalah hal yang penting dalam melakukan peramalan dikarenakan ketepatan model berguna untuk mengevaluasi hasil dari peramalan

yang telah dilakukan. Hasil peramalan terkadang muncul beberapa penyimpangan yang bisa disebabkan oleh faktor yang tidak diduga dimana tidak ada metode peramalan yang mampu menghasilkan peramalan yang akurat sehingga dibutuhkan ketepatan model. Banyak cara untuk menghitung ketepatan model, contohnya adalah *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE) dan *Mean Absolute Error* (MAE). Pada penelitian ini menggunakan MAPE untuk menentukan model terbaik. Sama seperti metode-metode lain, MAPE juga berfungsi untuk mencari nilai kesalahan pada suatu peramalan dan semakin kecil nilai galat pada suatu model maka semakin bagus pula model yang dihasilkan. Berikut untuk rumus MSE yaitu (Fatchurin, dkk., 2020):

$$MSE = \frac{\sum_{t=1}^n (Y_t - \widehat{Y}_t)^2}{n} \quad (2.24)$$

Sedangkan untuk rumus MAPE yaitu (Fatchurin, dkk., 2020):

$$MAPE = \frac{\sum_{t=1}^n \frac{|Y_t - \widehat{Y}_t|}{Y_t}}{n} \times 100\% \quad (2.25)$$

dengan:

Y_t = data aktual periode t

\widehat{Y}_t = data hasil peramalan periode t

n = banyaknya data.

Nilai MAPE yang dihasilkan mempunyai interpretasi sebagai berikut:

1. MAPE < 10% : peramalan sangat baik
2. MAPE 10% – 20% : peramalan baik
3. MAPE 20% – 50% : peramalan cukup
4. MAPE > 50% : peramalan tidak baik.

2.11 Minyak

Minyak mentah atau *crude oil* merupakan salah satu sumber daya yang sangat penting saat ini, dikarenakan hasil olahan minyak mentah merupakan sumber energi. Minyak mentah dapat diolah menjadi sumber energi, bahan bakar, sumber gas cair, industri kimia, produksi bahan serat, pembangkit listrik, dll (Sartika, 2017). Sumber daya alam yang tidak dapat diperbaharui salah satunya adalah minyak bumi. Sedangkan permintaan masyarakat akan minyak bumi selalu meningkat untuk memenuhi kebutuhan sehari-hari. Hal tersebut menyebabkan kapasitas minyak semakin hari semakin berkurang. Jika konsumsi terhadap minyak terus-menerus meningkat tetapi tidak diimbangi dengan ketersediaan minyak yang ada maka akan terjadilah kelangkaan sumber daya minyak. Dampak yang telah terjadi dari ketidakseimbangan antara produksi dan konsumsi minyak saat ini salah satunya adalah kenaikan harga minyak yang berfluktuatif (Fauzanissa, dkk., 2016). Harga minyak diukur menggunakan harga spot pasar minyak dunia. Standar harga minyak dunia umumnya mengacu pada *West Texas Intermediate* (WTI). Menurut Rahman, 2008 dalam Fauzannissa (2016) harga minyak dunia dipengaruhi oleh tiga faktor, yaitu:

1. Faktor pertama adalah faktor fundamental, yang terdiri atas permintaan minyak, pasokan minyak, stok minyak, kapasitas produksi cadangan dunia, dan kemampuan kilang dunia.
2. Faktor kedua adalah faktor non fundamental, yang terdiri dari geopolitik, kebijakan pemerintah, cuaca, bencana alam, dan pelemahan nilai dollar.
3. Faktor ketiga adalah pengaruh dari kebijakan pasokan OPEC.

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2022/2023 bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu data historis harga mingguan minyak dunia periode 1 September 2017 sampai 9 Oktober 2022 yang diperoleh dari <https://id.investing.com/> dengan jumlah data sebanyak 267 data. Satuan harga minyak yang digunakan yaitu satu *barrel* (159 liter) dalam satuan US Dollar. Pada penelitian ini, data dibagi menjadi 2 bagian yaitu data *training* untuk pembentukan model dan data *testing* untuk pemilihan model terbaik. Untuk proses pembagian datanya dibagi menjadi 3 bagian. Pertama, 70% data *training* dan 30% data *testing*. Kedua, 80% data *training* dan 20% data *testing*. Ketiga, 90% data *training* dan 10% data *testing*.

3.3 Metode Penelitian

Dalam penelitian ini dilakukan analisis menggunakan algoritma *Backpropagation Neural Network* untuk memprediksi harga minyak dunia dengan bantuan bahasa pemrograman *Python*. Adapun langkah-langkah yang dilakukan sebagai berikut:

1. Melakukan analisis deskriptif dengan memvisualisasikan data ke dalam plot deret waktu.
2. Menentukan input jaringan berdasarkan lag-lag yang signifikan pada plot PACF
3. Melakukan normalisasi data.
4. Melakukan pembagian data yaitu data *training* dan data *testing*.
5. Menentukan fungsi aktivasi.
6. Pembuatan model *Backpropagation Neural Network*:
 - a. Melakukan proses *training*.
 - b. Melakukan proses *testing*.
7. Melakukan denormalisasi data.
8. Melakukan visualisasi data pada hasil prediksi.

V. KESIMPULAN

Berdasarkan hasil dan pembahasan, diperoleh kesimpulan bahwa metode *Backpropagation Neural Network* (BNN) memiliki performa yang cukup baik untuk menganalisis harga minyak dunia. Dengan hasil uji yang didapat pada metode BNN dengan pembagian data pelatihan 70% dan data pengujian 30% memiliki nilai galat terkecil dengan nilai MSE sebesar 0.019 dan MAPE sebesar 0.0834.

DAFTAR PUSTAKA

- Aden. 2020. *Forecasting The Exponential Smoothing Methods*. Unpam Press, Tangerang Selatan.
- Astuti, E.D. 2009. *Pengantar Jaringan Syaraf Tiruan*. Star Publishing, Wonosobo.
- Fatchurin, E., Fanani, A., & Hafiyusholeh, M. 2020. Peramalan Penggunaan Bahan Bakar pada Pembangkit Listrik Tenaga Gas Uap menggunakan Metode Backpropagation Neural Network. *Jurnal Riset dan Aplikasi Matematika*. **4**(2): 82-92.
- Fausett, L.V. 1994. *Fundamentals of Neural Networks: Architecture, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Fauzannissa, R.A., Yasin, H., & Ispriyanti, D. 2016. Peramalan Harga Minyak Mentah Dunia Menggunakan Metode Radial Basis Function Neural Network. *Jurnal Gaussian*. **5**(1): 193-202.
- Hanifah. T.T., Adiwijaya, & Al-Faraby, S. 2017. Analisis Churn Prediction pada Data Pelanggan PT. Telekomunikasi dengan Logistic Regression dan Underbagging. *Jurnal Teknik Informatika Universitas Telkom*. **4**(2): 320-3225
- Hanke, J.E. & Winchern, D.W. 2004. *Business Forecasting*. 8th Edition. Pearson Education Inc., United States of Amerika.
- Herjanto, E. 2006. *Manajemen Operasi Edisi Ketiga*. Grasindo, Jakarta.

- Hidayat, R. & Suprpto. 2012. Meminimalisasi Nilai Error Peramalan dengan Algoritma Extreme Learning Machine. *Jurnal Optimasi Sistem Industri UNAND*. **11**(1): 187-192.
- Kusuma, P.D. 2020. *Machine Learning Teori, Program, dan Studi Kasus*. Deepublish, Yogyakarta.
- Machmudin, A. & Ulama, B.S.S. 2012. Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni*. **1**(1): 2086-4930.
- Makridis, S., Wheelwright, S.C., & McGee, V.E. 1999. *Metode dan Aplikasi Prediksi*. 2nd Edition. Terjemah Untung Sus Andriyanto. Erlangga, Jakarta
- Montgomery, D. 1990. *Pengantar Pengendalian Kualitas Statistik*. Gajah Mada University Press, Yogyakarta.
- Nguyen, T.A., Ly, H.B., & Pham, B.T. 2020. Backpropagation Neural Network-Based Machine Learning Model for Prediction of Soil Friction Angle. *Mathematical Problems in Engineering*.
- Nurmila, N., Sugiharto, A., & Sarwoko, E.A. 2010. Algoritma Back Propagation Neural Network untuk Pengenalan Pola Karakter Huruf Jawa. *Jurnal Sains dan Seni*. **1**(1): 118-123.
- Purnomo, M.H. & Kurniawan, A. 2006. *Supervised Neural Network*. Graha Ilmu, Surabaya.
- Rinjani, S.N., Hoyyi, A. & Suparti. 2019. Pemodelan Fungsi Transfer dan Backpropagation Neural Network untuk Peramalan Harga Emas. *Jurnal Gaussian*. **8**(4): 474-485.
- Sartika, U. 2017. Pengaruh Inflasi, Tingkat Suku Bunga, Kurs, Harga Minyak Dunia, dan Harga Emas Dunia Terhadap IHSG dan JII di Bursa efek Indonesia. *Balance: Jurnal Akuntansi dan Bisnis*. **2**(2): 285-294.

- Siang, J.J. 2005. *Jaringan Syaraf toruan & Pemrogramannya Menggunakan Matlab*. Penerbit ANDI, Yogyakarta.
- Siregar, S.P. & Wanto, A. 2017. Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm in Predicting Process (Forecasting). *IJISTECH (International Journal of Information System and Technology)*. **1**(1): 34-42.
- Untoro, A.B. 2020. Prediksi Harga Saham Dengan Menggunakan Jaringan Syaraf Tiruan. *Jurnal Teknologi Informatika dan Komputer*. **6**(2): 103-111.
- Utami, A.T.W. & Ulama, B.S.S. 2015. Penerapan Backpropagation untuk Meningkatkan Efektivitas Waktu dan Akurasi pada Data Wall-Following Robot Navigation. *Jurnal Sains dan Seni ITS*. **4**(2): 279-284.
- Warsito, B. 2009. *Kapita Selekta Statistika Neural Network*. Badan Penerbit UNDIP, Semarang,
- Wei, W.W. 2006. *Time Series Analysis Univariate and Multivariate Methods*. 2nd Edition. Pearson Education, Canada.
- Widiastuti, F., Kaswidjanti, W. & Rustamaji, H. C. 2014. Jaringan Saraf Tiruan Backpropagation untuk Aplikasi Pengenalan Tanda Tangan. *Telematika*. **11**(1): 69-76