

**STUDI KOMPARASI PERAMALAN HARGA MINYAK  
MENTAH MENGGUNAKAN METODE *GENERALIZED  
REGRESSION NEURAL NETWORK* DAN *FEED FORWARD  
NEURAL NETWORK***

**( Studi Kasus : Harga Minyak Mentah *West Texas Intermediate* )**

**TUGAS AKHIR**

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Program  
Studi Statistika



Febby Anggraita Yuwinda Putri

14 611 210

**JURUSAN STATISTIKA**

**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM**

**UNIVERSITAS ISLAM INDONESIA**

**2018**

## HALAMAN PERSETUJUAN PEMBIMBING

### TUGAS AKHIR

Judul : Studi Komparasi Peramalan Harga Minyak Mentah Menggunakan Metode *Generalized Regression Neural Network* dan *Feed Forward Neural Network* (Studi Kasus : Minyak Mentah *West Texas Intermediate*)

Nama Mahasiswa : Febby Anggraita Yuwinda Putri

Nomor Mahasiswa : 14 611 210

TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK  
DIUJIKAN

Yogyakarta, 02 Mei 2018

Pembimbing,



( Kariyam, S.Si., M.Si )



# HALAMAN PENGESAHAN

## TUGAS AKHIR

### STUDI KOMPARASI PERAMALAN MENGGUNAKAN METODE GENERALIZED REGRESSION NEURAL NETWORK DAN FEED FORWARD NEURAL NETWORK

( Studi Kasus : Harga Minyak Mentah *West Texas Intermediate* )

Nama Mahasiswa : Febby Anggraita Yuwinda Putri

Nomor Mahasiswa : 14 611 210

TUGAS AKHIR INI TELAH DIUJIKAN

PADA TANGGAL 05 JUNI 2018

Nama Penguji

Tanda Tangan

1. Dr. Kartiko, M.Si

2. M. Hasan Sidiq Kurniawan, M.Sc

3. Kariyam, M.Si

Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Drs. Alwar, M.Sc., Ph.D

## KATA PENGANTAR



*Assalammu'alaikum Wr. Wb.*

Puji syukur kepada Allah SWT yang telah mencurahkan rahmat, taufiq dan hidayah-Nya. Shalawat serta salam semoga selalu tercurah kepada Nabi Muhammad SAW serta para sahabat dan pengikutnya sampai akhir jaman. sehingga penulis dapat menyelesaikan tugas akhir ini yang Studi Komparasi Peramalan Harga Minyak Mentah *West Texas Intermediate* Menggunakan Metode *Generalized Regression Neural Network* Dan *Feed Forward Neural Network* tanpa halangan yang berarti.

Tugas akhir ini merupakan suatu perwujudan dari pembelajaran yang diperoleh oleh penulis selama menempuh kuliah di jurusan Statistika Universitas Islam Indonesia. Selama proses penyusunan tugas akhir ini penulis menyadari banyak mendapatkan dukungan, bantuan, dan arahan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan rasa terima kasih kepada:

1. Bapak Drs. Alwar, M.Sc., Ph.D selaku dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
2. Bapak Dr. RB Fajriya Hakim, S.Si., M.Si, selaku Ketua Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.
3. Ibu Kariyam, S.Si., M.Si selaku dosen pembimbing tugas akhir mulai dari saat penulis menentukan tema hingga selalu sabar dan memberi banyak masukan serta pengetahuan selama membimbing penulis hingga penulis dapat menyelesaikan tugas akhir.
4. Dosen-dosen Statistika UII yang telah membina dan mendedikasikan ilmunya untuk penulis.
5. Kedua orang tua tercinta, Bapak dan Ibu yang selalu memberikan doa, dukungan, kasih sayang dan beliau lah semangat terbesar penulis.

6. Sahabat kampus tercinta Ita Qorry Aina, Sri Hardianti, Ekha Zulaikha dan Wilda Zulvia dan seluruh teman-teman Statistika UII 2014 yang selalu memberikan dukungan serta bantuan selama proses penyusunan tugas akhir penulis.
7. Sahabat-sahabat KKN Purworejo unit 112 dan juga sahabat-sahabat SMA 1 Sentolo Yogyakarta, dan juga semua pihak yang telah membantu penulis.

Semoga Allah SWT. akan selalu memberi rahmat dan anugerah-Nya kepada mereka semua tanpa henti.

Penulis menyadari bahwa dalam penyusunan tugas akhir ini masih terdapat berbagai kekurangan karena keterbatasan pengetahuan dan kemampuan penulis. Oleh karena itu kritik dan saran yang bersifat membangun diharapkan oleh penulis, semoga tugas akhir ini bermanfaat bagi semua pihak. *Aamin.*

*Wassalamu 'alaikum Wr.Wb*

Yogyakarta, Maret 2018

Penulis

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PERSETUJUAN PEMBIMBING .....</b>	<b>ii</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>iii</b>
<b>KATA PENGANTAR.....</b>	<b>iv</b>
<b>DAFTAR ISI.....</b>	<b>vi</b>
<b>DAFTAR TABEL.....</b>	<b>ix</b>
<b>DAFTAR GAMBAR.....</b>	<b>x</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xi</b>
<b>PERNYATAAN.....</b>	<b>xii</b>
<b>INTISARI.....</b>	<b>xiii</b>
<b>ABSTRACT .....</b>	<b>xiv</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah .....	3
1.3. Batasan Masalah.....	3
1.4. Tujuan Penelitian.....	3
1.5. Manfaat Penelitian.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
<b>BAB III LANDASAN TEORI.....</b>	<b>8</b>
1.1. Analisis Data <i>Time Series</i> .....	8
1.2. Stasioneritas .....	9

1.3. <i>Autocorrelation Function (ACF) dan Partial Autocorrelation</i> .....	
<i>Function PACF</i> .....	10
1.4. <i>Artificial Neural Network</i> .....	12
1.5. <i>Arsitektur Neural Network</i> .....	13
1.6. <i>Fungsi Aktivasi Neural Network</i> .....	15
3.6.1 <i>Fungsi Biner dengan Threshold (Batas Ambang)</i> .....	15
3.6.2 <i>Fungsi Biner Sigmoid</i> .....	15
3.6.3 <i>Fungsi Bipolar Sigmoid</i> .....	16
3.6.4 <i>Fungsi Identitas (Purelin)</i> .....	16
1.7. <i>Jaringan Radial Basis</i> .....	16
1.8. <i>Pelatihan Data Neural Network</i> .....	18
1.9. <i>Regresi Kernel</i> .....	19
3.10. <i>Generalized Regression Neural Network (GRNN)</i> .....	19
3.11. <i>Arsitektur Jaringan GRNN</i> .....	21
3.12. <i>Feed Forward Neural Network (FFNN)</i> .....	23
3.13. <i>Normalisasi dan Denormalisasi</i> .....	27
3.14. <i>Ukuran Ketepatan Peramalan</i> .....	28
3.15. <i>Minyak Bumi</i> .....	29
3.16. <i>Organization of the Petroleum Exporting</i> .....	
<i>Countries (OPEC)</i> .....	30
<b>BAB IV METODOLOGI PENELITIAN</b> .....	<b>31</b>
4.1. <i>Populasi dan Sampel Penelitian</i> .....	31
4.2. <i>Variabel Penelitian</i> .....	31
4.3. <i>Metode Pengumpulan Data</i> .....	31
4.4. <i>Metode Analisis Data</i> .....	31
4.5. <i>Tahapan Analisis Data</i> .....	32
4.6. <i>Diagram Alur Penelitian Data</i> .....	33
<b>BAB V HASIL DAN PEMBAHASAN</b> .....	<b>35</b>
5.1. <i>Analisis Deskriptif</i> .....	35

5.2. Pendefinisian Model <i>Input</i> Jaringan.....	36
5.3. Peramalan Harga Minyak Mentah WTI Menggunakan .....	
Metode <i>Generalized Regression Neural Network</i> (GRNN).....	38
5.3.1. Pelatihan Jaringan GRNN .....	38
5.3.2. Pengujian Jaringan GRNN .....	41
5.3.3. Peramalan Minyak Mentah WTI Pada Jaringan.....	
GRNN.....	42
5.4. Peramalan Harga Minyak Mentah WTI Menggunakan .....	
Metode <i>Feed Forward Neural Network</i> (FFNN) .....	45
5.4.1. Arsitektur Jaringan FFNN .....	45
5.4.2. Pelatihan Jaringan FFNN .....	47
5.4.3. Pengujian Jaringan FFNN .....	52
5.4.4. Peramalan Minyak Mentah WTI Pada Jaringan.....	
FFNN .....	53
<b>BAB VI KESIMPULAN DAN SARAN.....</b>	<b>55</b>
6.1. Kesimpulan.....	55
6.2. Saran.....	56
<b>DAFTAR PUSTAKA .....</b>	<b>57</b>
<b>LAMPIRAN</b>	



## DAFTAR TABEL

<b>Tabel 2.1</b>	Persamaan dan Perbedaan dengan Penelitian Terdahulu pada Metode GRNN	6
<b>Tabel 2.2.</b>	Persamaan dan Perbedaan dengan Penelitian Terdahulu pada Metode FFNN	7
<b>Tabel 5.1.</b>	Partisi Data	37
<b>Tabel 5.2.</b>	Perbandingan Normalisasi dan Denormalisasi	37
<b>Tabel 5.3.</b>	Hasil Peramalan Harga Minyak GRNN	43
<b>Tabel 5.4.</b>	Pembentukan Arsitektur Jaringan FFNN	45
<b>Tabel 5.5.</b>	Bobot Awal <i>Input Layer</i>	47
<b>Tabel 5.6.</b>	Bobot Bias Awal <i>Input Layer</i>	47
<b>Tabel 5.7.</b>	Bobot Neuron <i>Hidden Layer Pertama</i>	48
<b>Tabel 5.8.</b>	Bobot Bias Neuron <i>Hidden Layer Pertama</i>	48
<b>Tabel 5.9.</b>	Bobot Neuron <i>Hidden Layer Kedua</i>	48
<b>Tabel 5.10.</b>	Bobot Bias Neuron <i>Hidden Layer Kedua</i>	48
<b>Tabel 5.11.</b>	Bobot Akhir <i>Input Layer</i>	49
<b>Tabel 5.12.</b>	Bobot Bias Akhir <i>Input Layer</i>	51
<b>Tabel 5.13.</b>	Bobot Akhir Neuron <i>Hidden Layer Pertama</i>	50
<b>Tabel 5.14.</b>	Bobot Bias Akhir Neuron <i>Hidden Layer Pertama</i>	50
<b>Tabel 5.15.</b>	Bobot Akhir Neuron <i>Hidden Layer Kedua</i>	50
<b>Tabel 5.16.</b>	Bobot Bias Akhir Neuron <i>Hidden Layer Kedua</i>	50
<b>Tabel 5.17.</b>	Hasil Peramalan Harga Minyak FFNN	53

## DAFTAR GAMBAR

<b>Gambar 3.1.</b>	Pola Data <i>Time Series</i>	9
<b>Gambar 3.2.</b>	Gambar Jaringan Lapis Tunggal	14
<b>Gambar 3.3.</b>	Jaringan Multilayer	14
<b>Gambar 3.4.</b>	Fungsi Biner Sigmoid	15
<b>Gambar 3.5.</b>	Fungsi Identitas	16
<b>Gambar 3.6.</b>	Plot Jaringan Radial Basis	17
<b>Gambar 3.7.</b>	Arsitektur GRNN	22
<b>Gambar 3.8.</b>	Arsitektur FFNN	24
<b>Gambar 4.1.</b>	Diagram Alur Penelitian	34
<b>Gambar 5.1.</b>	Grafik Harga Minyak Mentah WTI Tahun 2005-2017	35
<b>Gambar 5.2.</b>	Pergerakan Harga Minyak WTI Tahun 2005-2018	36
<b>Gambar 5.3.</b>	Plot PACF Harga Minyak Mentah WTI	36
<b>Gambar 5.4.</b>	Arsitektur GRNN Peramalan Harga Minyak Mentah WTI	38
<b>Gambar 5.5.</b>	Grafik Optimalisasi <i>Spread</i>	38
<b>Gambar 5.6.</b>	Grafik Prediksi Data Pelatihan GRNN	39
<b>Gambar 5.7.</b>	Grafik Prediksi Data Pengujian GRNN	40
<b>Gambar 5.8.</b>	Struktur Jaringan FFNN	46
<b>Gambar 5.9.</b>	Grafik Bobot Random Jaringan FFNN	47
<b>Gambar 5.10.</b>	Grafik Prediksi Data Pelatihan FFNN	51
<b>Gambar 5.11.</b>	Grafik Prediksi Data Pengujian FFNN	52

## DAFTAR LAMPIRAN

**Lampiran 1** : Data Harga Minyak Mentah WTI

**Lampiran 2** : Data *Training*

**Lampiran 3** : Data *Testing*

**Lampiran 4** : Bobot Jaringan GRNN

**Lampiran 5** : Pelatihan Jaringan FFNN Pemrograman Matlab

**Lampiran 6** : *Source Code* GRNN

**Lampiran 7** : *Source Code* FFNN

STUDI KOMPARASI PERNYATAAN MINYAK MENTAH  
MENGUNAKAN METODE GENERALIZED REGRESSION NEURAL

Dengan ini penulis menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu perguruan tinggi di sepanjang pengetahuan penulis juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang diacu di dalam naskah ini dan diterbitkan dalam daftar pustaka.

INTISARI

Yogyakarta, 02 Mei 2018

*[Signature]*  
Penulis



Minyak mentah merupakan salah satu indikator penting angunan ekonomi di Indonesia. Pada saat ini Indonesia sangat bergantung minyak yang berarti bahwa Indonesia lebih banyak membeli dari luar karena persediaan minyak mentah yang ada tidak memenuhi kebutuhan yang ada dalam negeri. Untuk itu harga minyak mentah salah satu indikator yang penting untuk diperhatikan, salah satu jenis minyak yang digunakan pemerintah Indonesia adalah West Texas Intermediate (WTI). Pengambilan keputusan untuk menyikapi harga minyak mentah dunia yang cenderung tidak stabil ini harus dilakukan secara matang. Salah satu cara yang dapat dipersiapkan adalah dengan membuat peramalan harga minyak mentah dunia. Peramalan yang akan dilakukan menggunakan dua metode yaitu *Generalized Regression Neural Network (GRNN)* dan *Feed Forward Neural Network (FFNN)*. Dari kedua metode tersebut diketahui bahwa metode GRNN lebih handal digunakan untuk meramalkan harga minyak mentah WTI ini dengan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 88,99% pada tahap pengujian jaringan.

Kata Kunci : Minyak Mentah, WTI, GRNN, FFNN, MAPE

**STUDI KOMPARASI PERAMALAN HARGA MINYAK MENTAH  
MENGUNAKAN METODE *GENERALIZED REGRESSION NEURAL  
NETWORK* DAN *FEED FORWARD NEURAL NETWORK***

**Febby Anggraita Yuwinda Putri**

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Islam Indonesia

**INTISARI**

Minyak mentah merupakan salah satu indikator yang penting untuk pembangunan ekonomi di Indonesia. Pada saat ini Indonesia sudah menjadi negara net importir minyak yang berarti bahwa Indonesia lebih banyak mengimpor minyak mentah dari luar karena persediaan minyak mentah yang ada tidak mampu untuk memenuhi kebutuhan yang ada dalam negeri. Untuk itu harga minyak mentah dunia menjadi salah satu indikator yang penting untuk diperhatikan, salah satu acuan harga minyak yang digunakan pemerintah Indonesia adalah *West Texas Intermediate* (WTI). Pengambilan keputusan untuk menyikapi harga minyak mentah dunia yang cenderung tidak stabil ini harus dilakukan secara matang. Salah satu cara yang dapat dipersiapkan adalah dengan membuat peramalan harga minyak mentah dunia. Peramalan yang akan dilakukan menggunakan dua metode yaitu *Generalized Regression Neural Network* (GRNN) dan *Feed Forward Neural Network* (FFNN). Dari kedua metode tersebut diketahui bahwa metode GRNN lebih handal digunakan untuk meramalkan harga minyak mentah WTI ini dengan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 88,99% pada tahap pengujian jaringan.

**Kata Kunci :** Minyak Mentah, WTI, GRNN, FFNN, MAPE



**COMPARISON STUDY OF CRUDE OIL PRICE FORECASTING USING  
GENERALIZED REGRESSION NEURAL NETWORK AND FEED  
FORWARD NEURAL NETWORK**

**Febby Anggraita Yuwinda Putri**

*Department of Statistics, Faculty of Mathematics and Natural Sciences*

*Islamic University of Indonesia*

**ABSTRACT**

*Crude oil is one of the essential indicators for the economic development in Indonesia. At this time, Indonesia has become a net oil importer country. It means that Indonesia imports more crude oil from abroad since the existing crude oil supply is unable to meet the needs of the country. Therefore, the world's crude oil price becomes an important indicator to be considered. One of the oil price references used by the Government of Indonesia is West Texas Intermediate (WTI). The decision-making to respond to the world's crude oil prices which tend to be unstable should be done rationally. One of the ways that can be prepared is by forecasting the world crude oil prices. The forecasting will be done using two methods. They are Generalized Regression Neural Network (GRNN) and Feed Forward Neural Network (FFNN). From those two methods, GRNN is more reliable to forecast the WTI crude oil price with MAPE (Mean Absolute Percentage Error) value of 88.99% at the network testing stage.*

**Keywords :** *Crude Oil, WTI, GRNN, FFNN, MAPE*

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Ekonomi merupakan salah satu pilar yang sangat berperan bagi suatu negara, karena dengan regulasi perekonomian yang baik, akan mempengaruhi banyak hal di negara tersebut diantaranya adalah kebijakan pemerintah, kesejahteraan masyarakat dan juga hubungan internasional. Menurut data Badan Pusat Statistik (BPS) pada tahun 2015 terdapat lima sektor terbesar yang mempengaruhi perekonomian di Indonesia, yang pertama yaitu sektor industri manufaktur dan Migas, yang kedua sektor pertanian dan perhutanan, kemudian sektor perdagangan, sektor konstruksi dan yang terakhir sektor pertambangan dan penggalan.

Dapat dilihat dari kelima faktor yang paling mempengaruhi perekonomian Indonesia tersebut, sektor industri manufaktur dan Migas menduduki peringkat pertama dalam mempengaruhi perekonomian di Indonesia. Salah satu aspek dari sektor ini adalah minyak, pada saat ini Indonesia sudah menjadi negara net importir minyak yang berarti bahwa Indonesia lebih banyak mengimpor minyak mentah dari luar karena persediaan minyak mentah yang ada di Indonesia itu sendiri tidak mampu untuk memenuhi kebutuhan yang ada dalam negeri. Untuk itu harga minyak mentah dunia menjadi salah satu indikator yang penting untuk diperhatikan karena kenaikan ataupun penurunan harga minyak mentah juga akan berdampak pada banyak aspek salah satunya apabila harga minyak mentah naik maka seluruh sektor industri maupun jasa yang membutuhkan minyak sebagai bahan untuk menjalankan usahanya juga akan menaikkan biaya produksinya.

Selain biaya produksi, hal yang juga akan berdampak secara langsung adalah transportasi, apabila harga minyak mentah naik maka harga bahan bakar minyak (BBM) juga akan ikut naik, karena hal tersebut kemudian harga barang-barang dan jasa juga akan ikut naik, dan dapat menyebabkan

berkurangnya daya beli masyarakat, dan juga penurunan nilai mata uang Rupiah, yang secara tidak langsung juga akan menyebabkan inflasi pada negara.

Pemerintah juga bisa saja tidak menaikkan harga BBM namun pemerintah juga harus berhati-hati dengan efek pemberian subsidi yang semakin membesar dan kemudian akan menyebabkan membengkaknya anggaran pemerintah yang sudah dipersiapkan sebelumnya. Oleh karena efeknya yang berkepanjangan, maka pengambilan keputusan untuk menyikapi harga minyak mentah dunia yang cenderung tidak stabil ini harus dilakukan secara matang. Salah satu cara yang dapat dipersiapkan adalah dengan membuat peramalan harga minyak mentah dunia, terdapat 2 nilai standar yang digunakan pemerintah Indonesia sebagai patokan dalam menilai harga minyak mentah dunia yaitu *Brent Crude Oil* dan *West Texas Intermediate* (WTI). Dalam tulisan ini akan dilakukan peramalan harga minyak mentah WTI.

Terdapat banyak metode peramalan klasik yang telah digunakan pada saat ini salah satu contohnya adalah ARIMA Box Jenkins, metode ARIMA Box Jenkins ini sangat baik akurasi untuk meramalkan suatu data dalam jangka yang pendek, namun untuk meramalkan data dalam jangka yang panjang akurasi akan semakin mengecil dan hasilnya akan cenderung konstan. Oleh sebab itu, ditemukannya metode jaringan syaraf tiruan atau *Artificial Neural Network* (ANN) telah menjadi solusi untuk permasalahan ini, karena dari penelitian-penelitian sebelumnya dikatakan bahwa jaringan syaraf tiruan ini sangat baik akurasi meskipun digunakan untuk peramalan jangka panjang. Terdapat beberapa metode peramalan menggunakan jaringan syaraf tiruan diantaranya adalah *Generalized Regression Neural Network* (GRNN) dan *Feed Forward Neural Network* (FFNN). Selanjutnya peramalan harga minyak mentah WTI akan dilakukan dengan menggunakan 2 metode yaitu metode jaringan syaraf tiruan tersebut. Kedua metode peramalan ini merupakan pengembangan dari metode basisnya yaitu *Artificial Neural Network* (ANN), karena keduanya berasal dari pengembangan metode yang sama, maka hasil peramalan ini nantinya juga dapat membuktikan metode manakah yang paling terbaik untuk meramalkan minyak mentah WTI.

## 1.2. Rumusan Masalah

Berdasarkan permasalahan yang telah dipaparkan dalam latar belakang, berikut ini adalah beberapa rumusan masalah yang akan diuraikan :

1. Bagaimana estimasi model peramalan harga minyak mentah *West Texas Intermediate* (WTI) masing-masing yang dihasilkan oleh metode *Generalized Regression Neural Network* dan *Feed Forward Neural Network*?
2. Metode mana yang paling sesuai untuk meramalkan minyak mentah WTI diantara *Generalized Regression Neural Network* dan *Feed Forward Neural Network* ?

## 1.3. Batasan Masalah

Adapun berikut ini adalah batasan masalah yang diberikan oleh peneliti :

1. Data yang digunakan dalam penelitian ini adalah data harga minyak mentah dunia yang didasarkan pada produk *West Texas Intermediate* (WTI), pada periode Januari 2005 – Februari 2018 yang berjumlah 158 data untuk masing-masing variabel.
2. Metode peramalan yang digunakan merupakan 2 metode *Artificial Neural Network* yaitu *Generalized Regression Neural Network* (GRNN) dan *Feed Forward Neural Network* (FFNN).

## 1.4. Tujuan Penelitian

Tujuan dari penelitian ini adalah :

1. Mengetahui model peramalan harga minyak mentah *West Texas Intermediate* (WTI) masing-masing yang dihasilkan oleh metode *Generalized Regression Neural Network* dan *Feed Forward Neural Network*.
2. Mengetahui metode mana yang paling baik untuk meramalkan harga minyak mentah WTI antara metode *Generalized Regression Neural Network* (GRNN) dan *Feed Forward Neural Network* (FFNN), dengan menggunakan ukuran error MSE (*Mean Squared Error*) dan MAPE (*Mean Absolute Percentage Error*)

### **1.5. Manfaat Penelitian**

Berdasarkan tujuan penelitian yang telah dipaparkan maka berikut ini adalah manfaat dari penelitian ini.

1. Dengan mengetahui hasil peramalan harga minyak mentah WTI maka pemerintah maupun investor dapat mempersiapkan strategi untuk menyikapi kenaikan ataupun penurunan harga minyak mentah tersebut.
2. Dengan mengetahui metode yang paling baik diantara GRNN ataupun FFNN, maka selanjutnya dapat dilakukan peramalan harga minyak mentah WTI kembali dengan menggunakan metode yang terbaik.



## **BAB II**

### **TINJAUAN PUSTAKA**

Kegiatan yang bertujuan untuk memperkirakan apa yang akan terjadi di masa yang akan datang atau yang biasa disebut dengan peramalan ini banyak dilakukan oleh pelaku usaha bisnis di berbagai bidang seperti bidang ekonomi, keuangan, pemasaran, logistik dan lain sebagainya. Kegiatan peramalan dengan menggunakan metode *Generalized Regression Neural Network* (GRNN) maupun *Feed Forward Neural Network* (FFNN) sebelumnya juga pernah dilakukan, meskipun keduanya merupakan cabang dari metode Neural Network, namun keduanya memiliki karakteristik dan juga algoritma yang berbeda.

Peramalan dengan menggunakan metode GRNN pertama kali dilakukan oleh Specht (1991) yang didalamnya menjelaskan mengenai algoritma yang dijalankan oleh GRNN dengan basis regresi non linier, kemudian selanjutnya penelitian dengan menggunakan metode ini terus berkembang salah satunya adalah penelitian yang dilakukan oleh Adnyani (2012) pada penelitiannya yang berjudul "*Generalized Regression Neural Network (GRNN) pada Peramalan Data Time Series*", dengan membandingkan metode GRNN dengan metode peramalan lainnya yaitu ARIMA, dalam penelitian ini disimpulkan bahwa *Mean Square Error* (MSE) metode GRNN lebih kecil daripada MSE dari metode ARIMA, oleh sebab itu metode GRNN dinilai baik daripada metode ARIMA, dengan nilai MSE pada data trainingnya adalah sebesar 0,073 dan MSE pada data testingnya sebesar 0,1364. Selanjutnya peramalan menggunakan metode GRNN juga pernah dilakukan oleh Rezy Eko Caraka, Hasbi Yasin dan Alan Prahutama (2015), untuk meramalkan data return indeks harga saham Euro 50 dengan nilai RMSE pada tahap pelatihan sebesar 0,00095 dan pada tahap pengujian sebesar 0,00725.

Kemudian untuk peramalan menggunakan metode *Feed Forward Neural Network* hingga saat ini telah banyak dilakukan diantaranya adalah penelitian yang dilakukan oleh Edy Supriyanto (2004) yang berjudul "Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Harga Saham". Selain itu metode ini juga

pernah dilakukan oleh Felasufah Kusumadewi (2014) dalam penelitiannya yang berjudul “Peramalan Harga Emas Menggunakan *Feedforward Neural Network* dengan Algoritma *Backpropagation*”, dalam penelitiannya ini diramalkan harga emas untuk 3 periode yaitu pada periode Maret 2014-Mei 2014 yang didasarkan pada pengaruh harga minyak dunia, struktur jaringan terbaik yang diperoleh adalah dengan 3 neuron *input* dan 9 neuron pada lapis tersembunyi dengan menggunakan fungsi aktivasi *sigmoid bipolar*. Peramalan harga emas tersebut menghasilkan nilai *Mean Absolute Percentage Error* (MAPE ) sebesar 1,8178% pada data training dan 5,6808% pada data testing. Kemudian peramalan menggunakan metode FFNN ini juga pernah dilakukan oleh Riki Harliansyah dan Jamilatuzzahro (2017), untuk peramalan pada indeks nilai tukar komposit Indonesia 12 periode kedepan dengan struktur FFNN yang digunakan yaitu 3 variabel input, 1 *hidden layer* dengan 4, struktur ini memberikan nilai *error* dengan ukuran error RMSE sebesar 88,500. Berikut ini akan dipaparkan perbedaan penelitian kali ini dengan penelitian terdahulu.

**Tabel 2.1** Persamaan dan Perbedaan dengan Penelitian Terdahulu pada Metode GRNN

Metode		Penelitian oleh Andyani (2012)	Penelitian oleh Rezzy Eko Caraka, Hasbi Yasin dan Alan Prahutama (2015)
GRNN	<b>Persamaan</b>	-Membandingkan dengan metode lain -Menggunakan ukuran <i>error</i> MSE	-Tidak dibandingkan dengan metode yang lain -Input jaringan berdasarkan <i>lag</i> data yang signifikan
	<b>Perbedaan</b>	-Membandingkan dengan metode dari cabang yang sama (ANN)	-Menggunakan ukuran <i>error</i> RMSE -Dilakukan optimalisasi pemilihan nilai parameter

		-Menggunakan ukuran <i>error</i> MAPE -Input jaringan berdasarkan <i>lag</i> data yang signifikan	( $\sigma$ )
--	--	--	--------------

**Tabel 2.2** Persamaan dan Perbedaan dengan Penelitian Terdahulu pada Metode FFNN

Metode		Penelitian oleh Felasufah Kusumadewi (2014)	Riki Harliansyah dan Jamilatuzzahro (2017)
FFNN	<b>Persamaan</b>	- <i>Input</i> jaringan berdasarkan <i>lag</i> data yang signifikan -Menggunakan ukuran <i>error</i> MAPE	- Membandingkan dengan metode yang lain -Input jaringan berdasarkan <i>lag</i> data yang signifikan -Dilakukan optimalisasi pemilihan arsitektur jaringan
	<b>Perbedaan</b>	-Menggunakan ukuran <i>error</i> MSE -Dilakukan optimalisasi pemilihan nilai parameter pada jaringan	-Membandingkan dengan metode dari cabang yang sama (ANN) -Menggunakan ukuran <i>error</i> MSE dan MAPE -Dilakukan optimalisasi pemilihan nilai parameter pada jaringan

## BAB III

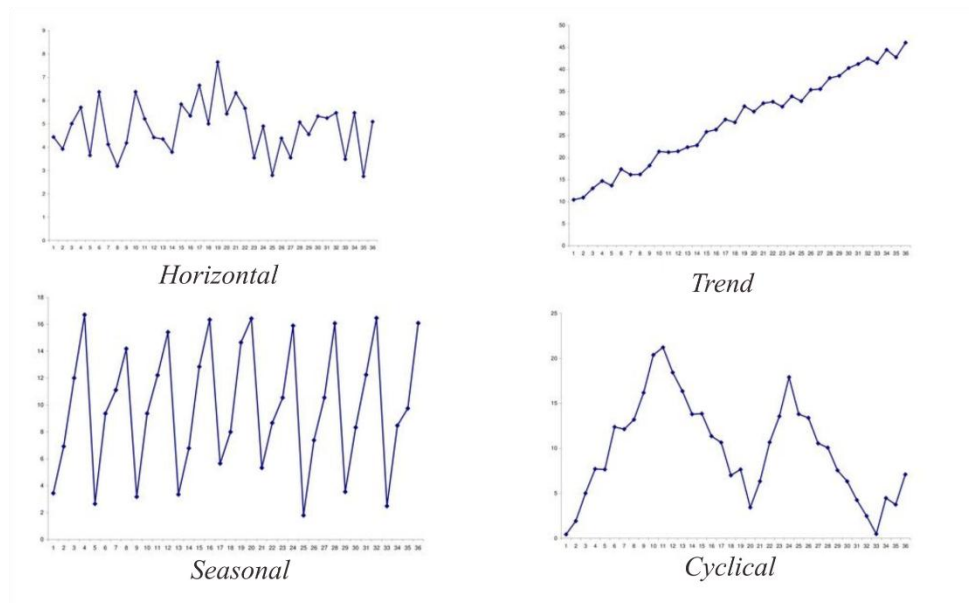
### LANDASAN TEORI

#### 3.1. Analisis Dasar Data *Time Series*

Data yang dikumpulkan, dicatat kemudian diobservasi berdasarkan urutan waktu secara historis atau berurutan merupakan data yang disebut dengan data runtun waktu atau disebut juga (*time series*). Secara umum analisis data *time series* merupakan analisis yang mempelajari pola variasi data di masa lalu dan dengan pola variasi yang telah ditemukan tersebut, kemudian digunakan untuk menemukan peramalan data untuk periode berikutnya. Data dikumpulkan secara periodik berdasarkan urutan waktu, bisa dalam jam, hari, minggu, bulan, kuartal dan tahun. Analisis *time series* ini juga dapat dilakukan untuk membantu dalam menyusun perencanaan strategi sebagai antisipasi resiko pada masa depan. Hal-hal penting yang harus diperhatikan dalam metode *time series* adalah menentukan jenis pola data historisnya, dengan memperhatikan tipe pola data, terdapat empat macam pola data *time series*, yaitu pola horizontal, pola trend, pola musiman dan pola siklis (Hanke dan Wichren, 2005).

1. *Horizontal* : adalah pola data yang naik atau turun (fluktuasi) disekitar nilai konstan.
2. *Trend* : pola data *trend* ditandai dengan adanya kenaikan ataupun penurunan dalam selang waktu pengamatan.
3. Musiman (*seasonal*) : pola data musiman ini dapat dikenali dengan melihat visualisasi data yang berbentuk fluktuasi berulang dalam selang waktu yang diamati.
4. Siklikal (*cyclical*) : pola data siklis adalah pola data yang fluktuasinya dipengaruhi oleh faktor-faktor tertentu dalam jangka yang panjang.

Berikut ini adalah contoh pola data time series yang membentuk pola *horizontal*, *trend*, *seasonal* maupun *cyclical*.



**Gambar 3.1** Pola Data *Time Series*

### 3.2. Stasioneritas

Dalam kasus peramalan menggunakan data runtun waktu, hasil peramalan akan lebih baik apabila data bersifat stasioner. Stasioner, yang artinya perubahan rata-rata, variansi maupun kovariansi dari data tersebut tidak tergantung pada perubahann waktu pengamatan (Juanda dan Junaidi, 2012). Perubahan ini diamati dari dua keadaan yaitu stasioner dalam rata-rata (*mean*) dan stasioner dalam variansi. Apabila data tidak bersifat stasioner dalam rata-rata maka akan dilakukan diferensiasi satu kali atau lebih sampai dengan mencapai kestasioneran. Namun apabila data tidak bersifat stasioner dalam variansi maka akan dilakukan transformasi yang sesuai misalnya transformasi *Box-Cox*.

*Differencing* atau diferensiasi merupakan selisih nilai saat ini dengan nilai terdahulu. Proses ini dilakukan dengan menggunakan notasi operator backshift (B) yang diformulasikan seperti berikut :

$$BX_t = X_{t-1} \quad (3.1)$$

Dengan pembeda pertama yaitu :

$$X'_t = X_t - X_{t-1} \quad (3.2)$$



$$\begin{aligned}
 &= X_t - BX_t \\
 &= (1 - B) X_t
 \end{aligned}$$

Kemudian secara umum pembeda orde ke-d adalah :

$$X_t^d = X_t(1 - B)^d X_t \quad (3.3)$$

Keterangan :

B = operator *backshift*

$X_t$  = data ke- $t$

$X_t^d$  = data *differencing*

### 3.3. Autocorrelation Function (ACF) dan Partial Autocorrelation Function PACF

Autokorelasi digunakan untuk menentukan koefisien korelasi pada deret berkala dan untuk mempelajari pola data termasuk trend atau musiman. Fungsi autokorelasi adalah semua himpunan autokorelasi untuk semua *lag*  $k$ .

$$\rho_k = \frac{\text{cov}(X_t, X_{t-k})}{\sqrt{\text{var}(X_t) \text{var}(X_{t-k})}} = \frac{\gamma_k}{\gamma_0} \quad (3.4)$$

Keterangan :

$\rho_k$  = autokorelasi pada *lag*  $k$

$t$  = waktu pengamatan

Estimasi  $\rho_k$  atau  $\hat{\rho}_k$  dilakukan dengan menggunakan autokorelasi dari pengamatan pada waktu  $t$  sampai pengamatan pada waktu  $t+k$ , rumus yang digunakan adalah sebagai berikut (Tsay, 2010: 31):

$$\hat{\rho}_k = r_k = \frac{\sum_{t=k+1}^n (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2}, k = 0, 1, 2, \dots \quad (3.5)$$

Keterangan :

$r_k$  = autokorelasi pada lag  $k$

$\bar{X}$  = rata-rata dari pengamatan

$X_t$  = pengamatan pada waktu ke- $t$

Signifikansi autokorelasi juga dapat ditentukan dengan melihat *correlogram*. *Correlogram* adalah plot antara lag  $k$  dengan  $r_k = 0$  yang direpresentasikan dengan garis putus-putus berwarna merah, sedangkan lag data direpresentasikan dengan garis tegak berwarna biru.

Selanjutnya *Partial Autocorrelation Function* (PACF) atau autokorelasi parsial digunakan untuk mengukur korelasi antara dengan setelah  $X_t$  dengan  $X_{t-k}$  setelah  $X_{t-1}$ ,  $X_{t-2}$ , ...,  $X_{t-k}$  dihilangkan. Autokorelasi parsial diformulasikan seperti berikut. Autokorelasi parsial diformulasikan seperti berikut (Montgomery, Jennings & Kulachi, 2008) :

$$\phi_{kk} = \frac{|\rho_k|}{|P_k|} \quad (3.6)$$

Keterangan :

$\phi_{kk}$  = nilai PACF ke  $k$

$\rho_k$  = nilai PACF pada lag  $k$

$P_k$  = nilai persamaan PACF pada aturan *Cramer*.

Rumus ini didasari dari persamaan Yule-Walker,

$$P_k \phi_{kk} = \rho_k \quad (3.7)$$

dengan

$$\rho_k = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \text{ dan } \phi_{kk} = \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix}$$

dan

$$P_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & \dots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix}$$

### 3.4. *Artificial Neural Network*

Otak manusia terdiri dari sinapsis, sinapsis adalah neuron-neuron penghubung dan memiliki struktur yang sangat kompleks. Dengan kekompleksan neuron yang ada dalam otak manusia tersebut maka otak manusia memiliki kemampuan yang luar biasa. Neuron yang ada pada otak manusia bekerja berdasarkan sinyal yang disebut dengan impuls, dengan sinyal inilah otak manusia dapat melakukan berbagai hal, mengenali pola, mengaktifkan fungsi yang ada pada organ tubuh dan lain sebagainya.

*Artificial Neural Network* (ANN) atau dalam bahasa Indonesia disebut sebagai Jaringan Syaraf Tiruan (JST) adalah sistem pemrosesan informasi yang terinspirasi dari berjalannya suatu proses yang menghasilkan keluaran dalam otak manusia misalnya pengenalan suatu benda, perintah penggerakan organ tubuh dan lain-lain. Pada JST informasi diproses pada neuron melalui penghubung, pada setiap penghubung antara neuron ini terdapat suatu bobot, bobot inilah yang akan bertugas untuk menyesuaikan sinyal yang masuk pada neuron pemrosesan, baik itu memperkuat sinyal maupun memperlemah sinyal. Untuk dapat mengaktifkan sinyal yang akan menghubungkan pada suatu neuron, JST ditentukan oleh 3 hal :

1. Pola hubungan antar neuron (arsitektur jaringan)
2. Penentuan bobot penghubung (*training/learning/algorithm*) dan
3. Fungsi aktivasi

Pada dasarnya JST tidak mampu menjelaskan bagaimana suatu hasil itu didapatkan, hal ini disebut dengan proses kotak hitam (*black box*). *Black box* proses ini hanya memperkirakan bagaimana suatu sistem aplikasi dapat menemukan suatu nilai *error* tanpa memperhatikan struktur algoritma internalnya. Keluaran atau *output* pada JST seluruhnya tergantung pada vektor *input* dalam


sistem, kemudian proses pengenalan *input* pada JST inilah yang akan berperan sebagai pemrosesan hingga didapatkan suatu *output* (Hermawan,2006).

Secara garis besar pada JST memiliki dua tahap pemrosesan informasi, yaitu tahap pelatihan dan tahap pengujian. Tahap yang pertama adalah tahap pelatihan, tahap pelatihan ini merupakan pengenalan pola-pola data *input* yang diproses kedalam jaringan. Pada tahap pelatihan ini akan didapatkan *output* yang didasarkan pada pemrosesan arsitektur jaringan dan bobot, sebelum mengeluarkan *output* yang optimal, jaringan terus melakukan iterasi untuk menyesuaikan bobot yang sesuai dengan nilai *error* yang diinginkan. Bobot yang telah sesuai dengan *error* pada tahap pelatihan inilah yang akan menjadi basis atau dasar pengetahuan pada tahapan selanjutnya yaitu tahap pengujian. Pada tahap pengujian dimasukkan data yang belum pernah dikenali sebelumnya (berbeda dengan data pelatihan) dan kemudian diproses menggunakan bobot yang menjadi dasar pengetahuan jaringan, harapan selanjutnya adalah bobot tersebut juga menghasilkan nilai *error* yang diinginkan pada tahap pengujian.

### **3.5. Arsitektur *Neural Network***


Arsitektur jaringan dalam *Neural Network* (NN) menjadi landasan yang paling utama pada pemrosesan *Neural Network*, dimana arsitek jaringan ini merupakan susunan dari neuron-neuron dalam suatu lapisan dan susunan penghubung antara suatu lapisan dengan lapisan yang lain. Didalam sebuah jaringan NN terdiri dari beberapa lapisan yaitu lapisan *input* (*input layer*) yaitu lapisan yang menerima *input* data yang akan diproses, kemudian lapisan tersembunyi (*hidden layer*) yaitu lapisan yang terletak diantara beberapa lapisan yang tidak berhubungan langsung dengan lapisan keluaran, dan yang terakhir adalah lapisan keluaran (*output layer*) yang bertugas untuk mengeluarkan *output* pemrosesan yang ada dalam jaringan. Arsitektur NN terdiri dari 2 model yaitu *single layer* dan *multilayer*.

Dalam jaringan lapis tunggal (*single layer*) pemrosesan yang terjadi dalam jaringan sangatlah sederhana, dimana neuron *input* akan berhubungan langsung dengan neuron *output* dan tentunya dengan pertimbangan bobot.



**Gambar 3.2.** Jaringan Lapis Tunggal

Jaringan multilapis (*multilayer*) merupakan proses jaringan yang lebih rumit dibandingkan dengan jaringan *single layer*. Dimana diantara *input layer* dan juga *output layer* terdapat sebuah *layer* tersembunyi (*hidden layer*). Jumlah dari lapisan tersembunyi tidak hanya 1 namun juga dapat bervariasi.



**Gambar 3.3.** Jaringan Multilayer

### 3.6. Fungsi Aktivasi *Neural Network*

Dalam jaringan syaraf tiruan, fungsi aktivasi dipakai untuk menentukan keluaran suatu neuron yang berarti fungsi aktivasi ini juga berfungsi sebagai transfer antar neuron. Fungsi aktivasi adalah masukan atau kombinasi linier antara

masukan dan bobotnya. Fungsi aktivasi ini merupakan suatu operasi dasar pada Neural Network, yang diproses bersama dengan penjumlahan bobot dan berguna sebagai pembangkit sinyal pada neuron. Terdapat beberapa jenis fungsi aktivasi antara lain: fungsi identitas, fungsi biner dengan threshold  $\Theta$ , fungsi biner sigmoid, fungsi bipolar sigmoid dan juga fungsi radial basis (Kristanto, 2004).

### 3.6.1. Fungsi Biner dengan *Threshold* (Batas Ambang)

Fungsi biner dengan threshold ini memproses input menjadi *output* yang akan bernilai 0 dan 1, atau yang biasa disebut dengan biner, atau tanda bipolarnya berharga -1 atau 1.

$$f(x) = \begin{cases} 1, & \text{jika } x \geq a \\ 0, & \text{jika } x < a \end{cases}$$

atau


$$f(x) = \begin{cases} 1, & \text{jika } x \geq a \\ -1, & \text{jika } x < a \end{cases}$$

### 3.6.2. Fungsi Biner Sigmoid

Fungsi biner sigmoid atau sering juga disebut dengan fungsi logistik sigmoid, sering digunakan sebagai fungsi aktivasi dari jaringan syaraf dengan jangkauan dari 0 ke 1 dan nilai *output* yang diharapkan juga bernilai biner yang berada diantara interval 0 dan 1.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.8)$$

Fungsi biner sigmoid ini hampir mirip dengan fungsi logistik dan membentuk kurva yang menyerupai huruf s.



**Gambar 3.4.** Fungsi Biner Sigmoid

### 3.6.3. Fungsi Bipolar Sigmoid

Berbeda dengan fungsi biner sigmoid, fungsi bipolar sigmoid memiliki jangkauan nilai dari -1 ke 1. Fungsi bipolar sigmoid diformulasikan sebagai berikut: (Fausset, 1994)


$$\begin{aligned} g(x) &= 2f(x) - 1 \\ &= \frac{2}{1 + \exp(-\sigma x)} - 1 \\ &= \frac{1 - \exp(-\sigma x)}{1 + \exp(-\sigma x)} - 1 \end{aligned} \quad (3.9)$$

### 3.6.4. Fungsi Identitas (*Purelin*)

Fungsi identitas atau *purelin* ini memproses nilai *output* yang memiliki pola sama dengan nilai *inputnya*, apabila menginginkan keluaran jaringan berupa sembarang bilangan riil dapat digunakan fungsi ini. Fungsi ini merupakan fungsi identitas untuk unit *input*

$$f(x) = x \quad (3.10)$$

fungsi identitas diilustrasikan sebagai berikut



**Gambar 3.5.** Fungsi Identitas

## 3.7. Jaringan Radial Basis

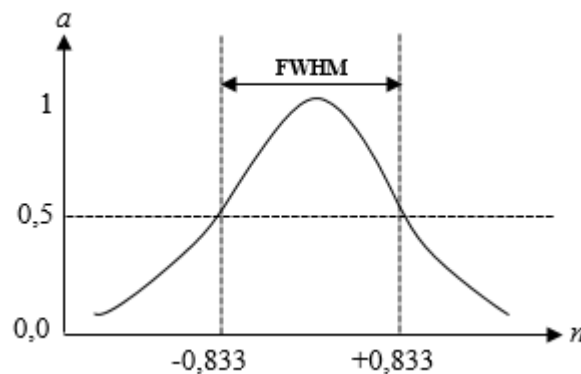
Jaringan basis radial adalah jaringan yang mengolah suatu *output* berupa kombinasi linier dari fungsi aktivasi dan juga nilai *input*. Apabila jarak vektor *input* dan juga vektor bobot yang diterima oleh jaringan radial basis bernilai nol (vektor bobot identik dengan vektor *input*), maka fungsi radial basis ini akan menghasilkan nilai maksimum satu.

Selanjutnya Jaringan ini terdiri dari tiga lapisan yaitu lapisan *input*, satu lapisan tersembunyi dengan aktivasi radial basis dan juga lapisan *output* dengan fungsi aktivasi linier (*purelin*).

Fungsi aktivasi yang digunakan dalam jaringan radial basis ini adalah sebagai berikut :

$$\begin{aligned} \text{Radbasis}(n) &= \theta_i = e^{-n^2} \\ \text{Radbasis}(n) &= \theta_i = e^{-\left(\frac{x_i - v_{ij}}{\sigma}\right)^2} \end{aligned} \quad (3.11)$$

Dimana  $x_i$  adalah vektor *input*, kemudian  $w_i$  adalah bobot *input*,  $b$  adalah bobot bias dan  $\sigma$  adalah *spread*.  $\theta_{ij}$  memiliki nilai maksimum 0,5 dengan digunakannya *full-width at half-maximum* (FWHM) yang berfungsi untuk menentukan luas kurva jaringan radial basis dengan mengilustrasikan sebuah persegi yang berujung pada tinggi dan lebar kurva Stamnes, (Knut dan Jakob, 2015)



**Gambar 3.6.** Plot Jaringan Radial Basis

Untuk itu pada saat nilai  $\theta_i$  adalah 0,5 dan apabila  $(x_i - v_{ij}) = \sigma$  maka nilai bobot bias pada jaringan radial basis ini akan dapat dijabarkan seperti berikut:

$$\begin{aligned} \theta_i &= e^{-\left(\frac{x_i - v_{ij}}{\sigma}\right)^2} \\ \theta_i &= e^{-(b)^2} \\ \ln \theta_i &= \ln e^{-(b)^2} \end{aligned}$$



$$\begin{aligned}
 \ln \theta_i &= -b^2 \\
 b^2 &= -\ln \theta_i \\
 b &= \sqrt{-\ln \theta_i} \\
 b &= \sqrt{-\ln 0,5} = 0,8326 \tag{3.12}
 \end{aligned}$$

### 3.8. Pelatihan Data *Neural Network*

Proses pelatihan pada *neural network* / jaringan syaraf tiruan merupakan suatu langkah terpenting. Pada tahap ini jaringan akan mempelajari pola data yang di atur dengan bobot-bobotnya, dimana keluaran dari proses pelatihan ini nantinya adalah bobot-bobot yang telah optimal dan akan dijadikan bobot basis pada tahap selanjutnya. Pelatihan jaringan syaraf tiruan ini terdiri dari 2 metode pelatihan yang pertama adalah metode pelatihan terbimbing (*supervised learning*) dan yang kedua metode pelatihan tidak terbimbing (*unsupervised learning*) (Yeung, 1998).

#### 1. Pelatihan terbimbing (*supervised learning*)

Inti dari pelatihan jaringan terbimbing adalah nilai *error*, mulai dari proses *input* data sampai dengan jalannya pemrosesan data melalui neuron yang berada pada layer tersembunyi sampai ke layer *output* hingga mendapat nilai *error* sesuai dengan yang diinginkan, apabila nilai *error* masih besar maka akan dilakukan pengulangan iterasi pemrosesan data hingga mencapai nilai *error* yang diinginkan. Pelatihan terbimbing juga memiliki target pada *outputnya*.

#### 2. Pelatihan tak terbimbing (*unsupervised learning*)

Berbeda dengan pelatihan terbimbing, pelatihan tak terbimbing tidak memiliki target pada pemrosesan pelatihan. Pada proses pelatihan ini, nilai bobot disusun dalam suatu interval atau *range* tertentu tergantung dari nilai *input* yang diberikan.

Algoritma pelatihan terbimbing dan tak terbimbing masing-masing mempunyai kelemahan, pelatihan terbimbing memang memiliki tingkat akurasi ketepatan yang tinggi namun prosesnya lebih kompleks dan juga memerlukan

waktu yang lama, sedangkan pelatihan tak terbimbing memiliki proses yang lebih sederhana dan dalam waktu yang singkat, namun pelatihan tak terbimbing memiliki tingkat akurasi ketepatan yang lebih rendah.

### 3.9. Regresi Kernel

Seperti pada umumnya, tujuan utama analisis regresi adalah untuk mengetahui pengaruh antara variabel independen ( $x$ ) terhadap variabel dependen ( $y$ ), hubungan antara  $x$  dan  $y$  pada regresi kernel diformulasikan sebagai berikut :

$$y = m(x_i) + \varepsilon \quad (3.13)$$

Dimana  $m$  adalah fungsi regresi dan  $\varepsilon$  adalah *error*, persamaan regresi kernel di atas tidak dapat diwujudkan namun fungsi  $m(x)$  dapat diestimasi dengan pendekatan nonparametrik.

$$\hat{m}(x) = \frac{\sum_{i=1}^n y_i w\left(\frac{x-X_i}{\Delta}\right)}{\sum_{i=1}^n w\left(\frac{x-X_i}{\Delta}\right)} \quad (3.14)$$

Dengan  $w(t) = w\left(\frac{x-X_i}{\Delta}\right)$  merupakan kernel, kernel normal berbentuk seperti berikut :

Dimana  $x$  adalah titik jangkauan biasanya digunakan jangkauan 0 atau 1, kemudian  $X_i$  adalah pengamatan data ke- $i$ ,  $k$  merupakan standar deviasi dan  $\Delta$  merupakan *bandwidth*. *Bandwidth* disini merupakan pengontrol kelulusan pada regresi kernel. Pemilihan nilai *bandwidth* menjadi sangat penting karena apabila nilai *bandwidth* terlalu kecil maka akan mengakibatkan data terlalu fluktuatif, namun apabila terlalu besar maka akan mengakibatkan data terlalu halus sehingga tidak nampak polanya.

### 3.10. Generalized Regression Neural Network (GRNN)

GRNN merupakan salah satu jaringan yang termasuk dalam jaringan radial basis. Regresi nonlinear Kernel menjadi dasar pengoperasian dari GRNN ini, dengan model pendugaan  $m(x)$  pada model regresi Kernel  $y = m(x_i) + \varepsilon$  adalah

$$\hat{m}(x) = E(y|X) = \frac{\int_{-\infty}^{\infty} y f(X,y) dy}{\int_{-\infty}^{\infty} f(X,y) dy} \quad (3.16)$$

Konsep utamanya yaitu nilai harapan *output* ditentukan oleh himpunan *input-inputnya* (Sprecht,1991). Dimana  $y$  merupakan *output* yang akan diprediksi oleh GRNN, kemudian  $X$  merupakan vektor *input* yang terdiri dari  $p$  variabel independen  $(x_1, x_2, \dots, x_p)$ , dan ekspektasi nilai  $y$  terhadap  $X$  atau  $E [y| X]$  merupakan nilai harapan dari *output*  $y$  jika diberikan vektor *input*  $X$  serta  $f(X, y)$  merupakan fungsi densitas probabilitas bersama dari  $X$  dan  $y$ .

Pada saat densitas probabilitas  $f(X, y)$  tidak diketahui, dapat diestimasi dengan menggunakan estimator konsisten nonparametrik yang diusulkan oleh parzen berikut ini.

$$f(X, y) = \frac{1}{[2\pi^{(p+1)/2\sigma^{(p+1)}}] n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] \quad (3.17)$$

Kemudian apabila persamaan (3.17) disubstitusikan ke persamaan (3.16) maka akan didapatkan :

$$\begin{aligned} E(y|X) &= \frac{\int_{-\infty}^{\infty} \frac{1}{[2\pi^{(p+1)/2\sigma^{(p+1)}}] n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] y dy}{\int_{-\infty}^{\infty} \frac{1}{[2\pi^{(p+1)/2\sigma^{(p+1)}}] n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] dy} \\ &= \frac{\frac{1}{[2\pi^{(p+1)/2\sigma^{(p+1)}}] n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \int_{-\infty}^{\infty} y \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] dy}{\frac{1}{[2\pi^{(p+1)/2\sigma^{(p+1)}}] n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \int_{-\infty}^{\infty} \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] dy} \\ &= \frac{\sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \int_{-\infty}^{\infty} y \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] dy}{\sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \int_{-\infty}^{\infty} \exp\left[-\frac{(y-y_i)}{2\sigma^2}\right] dy} \quad (3.18) \end{aligned}$$

Dengan  $n$  adalah banyaknya pengukuran dalam himpunan data pelatihan,  $h$  adalah suatu panjang bidang serta jarak matriks  $(D_i^2)$  dimisalkan :

$$D_i^2 = (x - x_i)^T (x - x_i) \quad (3.19)$$

maka diperoleh :

$$\hat{y}(X) = \frac{\sum_{i=1}^n y_i \exp\left[-\frac{D_i^2}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{D_i^2}{2\sigma^2}\right]} \quad (3.20)$$

Seperti konsep *bandwiht* pada regresi Kernel,  $\sigma$  adalah parameter penyebaran atau juga parameter *smoothing*, nilai  $\sigma$  yang terlalu besar akan mengakibatkan estimasi yang sangat halus dan tidak terlihat polanya, namun nilai  $\sigma$  yang terlalu kecil juga akan mengakibatkan pola data jauh dari pola Kernel, maka dari itu pemilihan  $\sigma$  harus dilakukan dengan beberapa kali percobaan dengan tolak ukur nilai *error* untuk menentukan nilai  $\sigma$  yang paling baik. Pada jaringan GRNN parameter *smoothing* ( $\sigma$ ), ditentukan melalui proses pelatihan jaringan. Pada banyak kasus,  $\sigma$  memberikan pengaruh yang cukup besar pada nilai *error* yang terbentuk pada jaringan. Untuk itu, pada penerapannya pemilihan  $\sigma$  menghasilkan nilai minimum MSE dengan menggunakan metode *trial and error*, yang akan menghasilkan kurva parabola (Zaknich dan Attikiouzel, 1993).

### 3.11. Arsitektur Jaringan GRNN

Pada dasarnya struktur jaringan GRNN sama dengan jaringan *neural network* pada umumnya, namun karena GRNN didasarkan pada teori regresi Kernel maka dari itu *output layer* untuk GRNN ini juga berasal dari estimasi fungsi  $m(x)$  pada model regresi Kernel.

Kemudian nilai  $\hat{y}$  yang diterapkan pada basis *neural network* dengan komputasi yang disederhanakan (Specht, 1991).

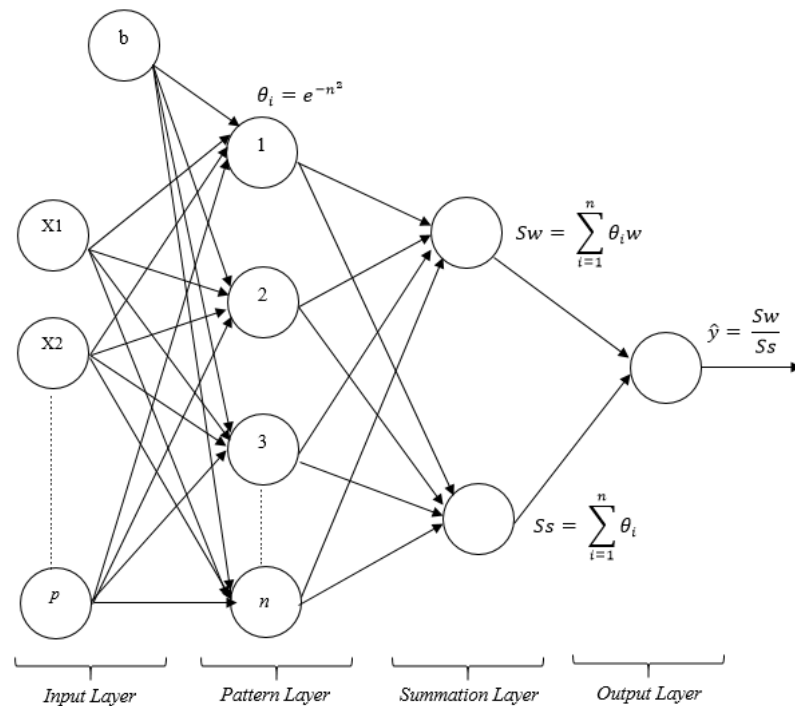
$$\hat{y}(X) = \frac{\sum_{i=1}^n y_i \exp\left[-\frac{D_i^2}{\sigma}\right]}{\sum_{i=1}^n \exp\left[-\frac{D_i^2}{\sigma}\right]} \quad (3.21)$$

dimana  $D_i^2$  akan dapat didekati dengan menggunakan jarak Euclidian antara vektor *input* dan vektor bobot *input* pada data pelatihan (Wasserman, 1993).

$$D_i^2 = \sum_{i=1}^p (x_i - v_{ij})^2$$

$$D_i = \sqrt{\sum_{i=1}^p (x_i - v_{ij})^2}, (i = 1, 2 \dots, n) \text{ dan } (j = 1, 2, \dots, p) \quad (3.22)$$

Terdapat 4 lapisan pada jaringan GRNN yaitu *input layer*, *pattern layer*, *summation layer* dan *output layer*. Arsitektur jaringan yang terbentuk pada GRNN memiliki jumlah neuron yang sama dengan himpunan data *input* pelatihan. Masing-masing *layer* pada pengolahan data dengan jaringan GRNN ini memiliki peranan yang berbeda-beda, pertama data akan diinput melalui *input layer*, *layer* ini hanya bertugas untuk menerima *input* data yang akan diolah. Kemudian selanjutnya vektor *input* akan diteruskan ke *pattern layer*, dalam *pattern layer* ini terdapat suatu fungsi aktivasi yang berfungsi sebagai transfer sinyal jaringan.



**Gambar 3.7.** Arsitektur GRNN

Pada jaringan GRNN fungsi aktivasi yang digunakan yaitu aktivasi radial basis.

$$\theta_i = e^{-n^2}$$

Dengan

$$n = b \cdot D_i \quad (3.23)$$

$b$  adalah bobot bias lapisan *input*, khusus pada GRNN bobot bias lapisan *input* ini bernilai  $0,8326/spread$  untuk semua neuron. Kemudian  $D_i$  akan dapat didekati dengan menggunakan jarak Euclidian (Persamaan (22, halaman 21)).

Jarak yang telah ditemukan kemudian akan digunakan untuk menemukan nilai fungsi aktivasi pada masing-masing neuron pada *input layer* ke *hidden layer*. Kemudian setelah fungsi aktivasi terbentuk, maka selanjutnya masuk pada *layer* atau lapisan selanjutnya yaitu *summation layer*, pada *layer* ini terdapat dua pemrosesan jaringan yang pertama adalah penjumlahan aritmatik terhadap fungsi aktivasi ( $S_s$ ) dan penjumlahan terboboti ( $S_w$ ), dimana bobot pada *layer* ini sama dengan nilai vektor target.

$$S_s = \sum_{i=1}^n \theta_i \quad (3.24)$$

dan,

$$S_w = \sum_{i=1}^n \theta_i w_i \quad (3.25)$$

Setelah didapatkan nilai penjumlahan nilai aktivasi dan nilai terboboti, kemudian masuk pada *output layer*, dimana *output* akan didapatkan dari nilai pembagian antara penjumlahan terboboti dan nilai penjumlahan fungsi aktivasi.

$$\hat{y} = \frac{S_w}{S_s} \quad (3.26)$$

### 3.12. Feed Forward Neural Network (FFNN)

FFNN merupakan salah satu pengembangan model *Neural Network*, sebagai koreksi kesalahan pada jaringan ini digunakan algoritma *Backpropagation*. Seperti pada arsitektur *Neural Network* pada umumnya, FFNN juga memiliki beberapa lapisan diantaranya adalah lapisan *input*, beberapa lapisan tersembunyi dan juga lapisan *output*. Jumlah lapisan tersembunyi dan neuron yang ada pada lapisan tersembunyi pada FFNN juga menentukan tingkat kompleksitas pada

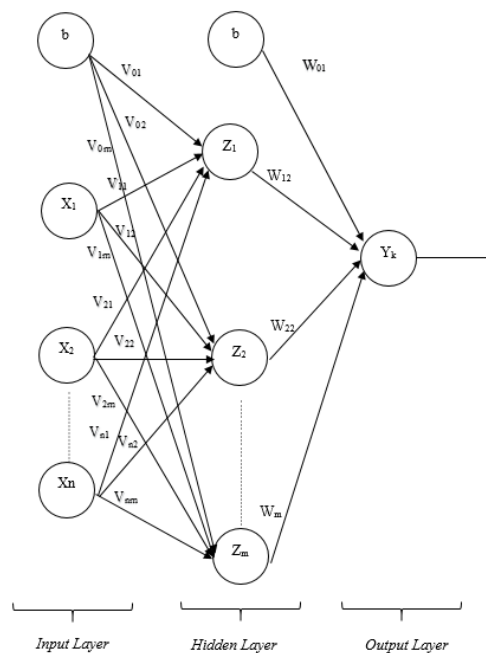
jaringan. Oleh sebab itu dilakukan beberapa uji untuk menentukan jaringan yang optimal dengan beberapa percobaan dengan jumlah neuron sesuai dengan formulasi berikut (Baum dan Haussler, 1988).

$$Z = 2^{N-1} \quad (3.27)$$

Keterangan :

$Z$  = Jumlah neuron *hidden layer* maksimal

$N$  = Jumlah variabel *input*



**Gambar 3.8.** Arsitektur FFNN

Terdapat dua fase yang ada dalam jaringan FFNN yaitu *fase feed forward* dan *fase backpropagation*.

### **Fase I : Feed Forward**

Pada fase ini dilakukan *input* data ke dalam jaringan, kemudian selanjutnya inisialisasi bobot dari *input* data (bobot diperoleh dengan cara random). Sama halnya dengan jaringan syaraf tiruan yang lain, pada FFNN ini juga terdapat tahapan pelatihan dan juga pengujian, pada tahapan pelatihan ini bobot-bobot

yang digunakan disusun secara acak dengan menggunakan nilai-nilai yang kecil, hal ini dikarenakan apabila nilai bobot awal terlalu besar, maka akan menyebabkan nilai turunan fungsi aktivasinya menjadi sangat kecil. Langkah selanjutnya adalah *input* beserta bobot diteruskan ke lapisan tersembunyi, pada proses ini terdapat fungsi aktivasi yang berguna untuk mentransfer sinyal pada neuron dalam lapisan tersembunyi, fungsi aktivasi yang digunakan biasanya adalah fungsi aktivasi sigmoid biner, yang di formulasikan sebagai berikut :

$$z_j = f(z_{net_j}) = \frac{1}{1+e^{-z_{net_j}}} \quad (3.28)$$

Dimana,

$$z_{net_j} = v_{0j} + \sum_{i=1}^n x_i v_{ji} \quad (3.29)$$

$z_j$  merupakan keluaran dari lapisan *input* ke lapisan tersembunyi, kemudian  $v_{0j}$  adalah bobot bias pada lapisan tersembunyi,  $x_i$  merupakan vektor *input* ke  $i$ , dan  $v_{ji}$  adalah bobot *input* terhadap unit tersembunyi.

Setelah didapatkan keluaran pada lapisan tersembunyi ( $z_j$ ) maka selanjutnya dapat dihitung *output* proses FFNN ini dengan menggunakan formulasi keluaran seperti berikut.

$$y_k = y_{net_k} = w_{0k} + \sum_{j=1}^p w_{kj} z_j \quad (3.30)$$

Dimana  $w_{0k}$  merupakan bobot bias pada unit *output*, dan  $w_{kj}$  adalah bobot unit tersembunyi terhadap unit *output*.

### **Fase II : Backpropagation**

Oleh karena bobot-bobot pada fase I disusun secara random dan tentunya akan menghasilkan nilai *error*, maka dari itu jaringan FFNN ini akan melakukan beberapa iterasi untuk mencapai bobot yang maksimal, berikut ini adalah formulasi untuk menentukan bobot-bobot yang maksimal pada jaringan FFNN.



- a. Bobot optimal pada lapisan *output*

$$W_{jk}baru = W_{jk}lama + \alpha \delta_k z_j \quad (3.31)$$

$$W_{0k}baru = W_{0j}lama + \alpha \delta_k \quad (3.32)$$

- b. Bobot optimal pada lapisan tersembunyi

$$V_{ij}baru = V_{ij}lama + \alpha \delta_j x_i \quad (3.33)$$

$$V_{0j}baru = V_{0j}lama + \alpha \delta_j \quad (3.34)$$

Dengan  $\delta_k$  adalah faktor kesalahan berdasarkan *error* disetiap keluaran pada lapisan output ( $Y_k$ ), dan  $\delta_j$  adalah faktor kesalahan pada masing-masing keluaran lapisan tersembunyi ( $z_j$ ).

$$\begin{aligned} \delta_k &= (T_k - Y_k)f'(Y_{net_k}) \\ &= (T_k - Y_k)Y_k(1 - Y_k) \end{aligned} \quad (3.35)$$

$$\delta_j = \delta_{net} z_j (1 - z_j) \quad (3.36)$$

Dimana,

$$\delta_{net} = \sum_{k=1}^m \delta_k W_{kj} \quad (3.37)$$

Terdapat beberapa faktor yang berfungsi untuk mengukur ketepatan kinerja jaringan FFNN, diantaranya adalah maksimum *Epoch*, kemudian momentum dan juga *learning rate*.

- a. Maksimum *Epoch*

*Epoch* atau dalam bahasa Indonesia adalah epoh adalah suatu nilai selang waktu dalam satu kali pembelajaran pada ANN, satu kali *epoch* berarti satu kali pembelajaran ANN. Iterasi yang dilakukan oleh jaringan akan terhenti apabila telah mencapai maksimum *epoch*.

- b. Momentum ( $\beta$ )

Momentum adalah perubahan bobot yang didasari oleh perubahan bobot sebelumnya, dari selang nilai momentum  $[0 \ 1]$ , nilai momentum 0,9 paling sering digunakan (Lin dan Lee, 1996).

c. *Learning Rate* ( $\alpha$ )

Learning rate menggambarkan kecepatan belajar jaringan untuk mengenali suatu pola data, semakin besar nilai learning rate maka akan mempercepat proses belajar tetapi hasil akhir jaringan akan jauh melampaui data yang sebenarnya, kemudian learning rate yang rendah akan berlaku sebaliknya. Nilai learning rate dari selang 0,01 sampai dengan 10 telah banyak memberikan hasil yang baik pada jaringan Neural Network ini (Lin dan Lee, 1996).

### 3.13. Normalisasi dan Denormalisasi

Pada metode GRNN dan FFNN memang tidak dibutuhkan asumsi normalitas, namun normalisasi data tetap dilakukan, hal ini bertujuan untuk meningkatkan performa peramalan atau dalam arti lain jaringan tidak mengalami kegagalan pada saat peramalan. Data pelatihan maupun pengujian dinormalisasikan pada interval 0 sampai dengan 1, hal ini disesuaikan dengan fungsi aktivasi yang digunakan pada metode GRNN dan FFNN ini yaitu fungsi aktivasi radial basis dan sigmoid biner. Normalisasi data tersebut dilakukan dengan menggunakan formulasi berikut :

$$X' = \frac{X-a}{b-a} \quad (3.38)$$

Keterangan :

- $a$  = data minimum
- $b$  = data maksimum
- $x$  = data aktual / data asli
- $X'$  = data normalisasi

Setelah jaringan terbentuk dan *output* dari masing-masing metode didapatkan, dibutuhkan data dalam bentuk seperti semula agar dapat dibandingkan dengan hasil data aktual yang dianalisis, hal ini dapat dilakukan dengan langkah denormalisasi.

$$X = a + (\hat{y} (b - a)) \quad (3.39)$$

Keterangan :

- $a$  = data minimum
- $b$  = data maksimum
- $\hat{y}$  = *output* (data keluaran)
- $X$  = data aktual

### 3.14. Ukuran Ketepatan Peramalan

Peramalan pada suatu penelitian adalah sesuatu yang mengandung unsur ketidakpastian. Ketidakpastian ini disebabkan oleh adanya suatu nilai *error*. *Error* yang dimaksud dalam peramalan ini adalah jarak antara hasil peramalan dengan data aktual. Terdapat banyak faktor yang dapat menyebabkan adanya suatu nilai *error* pada peramalan, diantaranya adalah faktor-faktor penentu nilai variabel yang diramalkan yang tidak diikuti dalam proses penelitian, kemudian juga metode peramalan yang tidak cocok dengan pola data yang diramalkan. Ukuran ketepatan peramalan dapat ditentukan oleh beberapa nilai berikut :

#### 1. *Mean Squared Error* (MSE)

MSE adalah nilai kesalahan yang dihitung dari rata-rata selisih data peramalan dengan data sebenarnya yang dikuadratkan (Subagyo, 1986)

$$MSE = \frac{\sum_{i=1}^n |X_t - \hat{X}_t|^2}{n} \quad (3.40)$$

Keterangan :

- $X_t$  : Data aktual
- $\hat{X}_t$  : Data Peramalan
- $n$  : Banyak data observasi

#### 2. *Mean Absolute Error* (MAE)

MAE adalah nilai kesalahan yang dihitung dari rata-rata selisih data peramalan dengan data sebenarnya.

$$MAE = \frac{\sum_{i=1}^n |X_t - \hat{X}_t|^2}{n} \quad (3.41)$$

Keterangan :

$X_t$  : Data aktual

$\hat{X}_t$  : Data Peramalan

$n$  : Banyak data observasi

### 3. Mean Absolute Percentage Error (MAPE)

Sederhananya MAPE adalah presentase dari nilai MAE yang dihitung dari rata-rata selisih data peramalan dengan data sebenarnya.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|X_t - \hat{X}_t|}{X_t} \quad (3.42)$$

### 3.15. Minyak Bumi

Minyak bumi adalah salah satu sumberdaya alam yang tidak dapat diperbaharui, meskipun begitu namun kebutuhan terhadap minyak bumi sangatlah besar baik untuk kepentingan sehari-hari maupun untuk bidang industri dan lainnya. Minyak bumi (*petroleum*) merupakan cairan yang mudah terbakar yang terdiri dari berbagai macam campuran hidrokarbon, yang sebagian besar merupakan alkana yang bervariasi bentuk serta kemurniannya (Sanusi,1984). Untuk sampai dapat dikonsumsi sebagai bahan bakar atau kegiatan sehari-hari, minyak bumi tidak dapat langsung digunakan begitu saja karena minyak bumi masih disebut sebagai minyak mentah apabila masih mengandung zat pengotor dan juga beracun bagi katalis pemroses. Untuk mendapatkan minyak yang dapat digunakan sebagai bahan bakar minyak mentah terlebih dahulu harus melalui tahap pengilangan.

Dari tahun ke tahun, kebutuhan terhadap minyak bumi terus meningkat, hal ini juga menyebabkan kenaikan pada harga minyak bumi itu sendiri, berikut ini adalah beberapa faktor yang menyebabkan kenaikan maupun penurunan harga minyak bumi :

1. Pertumbuhan ekonomi dunia

2. Suplai minyak bumi dari negara-negara OPEC
3. Suplai minyak bumi dari negara-negara non OPEC
4. Stok minyak bumi dari negara-negara OPEC
5. Faktor Dollar Amerika Serikat
6. Kebijakan negara-negara penghasil minyak bumi terbesar seperti Amerika Serikat dan Arab Saudi.
7. Perubahan musim dan juga cuaca.

### **3.16. *Organization of the Petroleum Exporting Countries (OPEC)***

OPEC adalah organisasi yang bertujuan menegosiasikan masalah-masalah mengenai produksi, harga dan hak konsesi minyak bumi dengan perusahaan-perusahaan minyak. Organisasi ini ada untuk menyeimbangkan beberapa ketimpangan peraturan sepihak yang dilakukan oleh perusahaan minyak terbesar di dunia seperti Exxon, Texaco, Gulf, British Petroleum dan juga Shell. Negara-negara yang menjadi anggota OPEC adalah negara pengekspor minyak mentah, dan mengatur negara-negara pengekspor minyak tersebut agar tidak dirugikan oleh pihak lain. Kemudian juga untuk negara-negara yang menjadi net importir minyak agar tetap dapat mengimpor harga minyak yang stabil. Terdapat 12 negara yang sampai saat ini menjadi bagian dari OPEC diantaranya Aljazair, Angola, Libya, Nigeria, Arab Saudi, Iran, Irak, Kuwait, Qatar, Uni Emirat Arab, Ekuador dan Venezuela. Kemudian negara yang telah keluar dari OPEC adalah Gabon, dan Indonesia.

Ada beberapa patokan harga minyak mentah yang menjadi standar regulasi perdagangan minyak mentah dunia yang diakui oleh OPEC, diantaranya yaitu *Brent Crude Oil* dan *West Texas Intermediate (WTI)*. Minyak mentah *Brent* adalah minyak mentah hasil pengolahan perusahaan minyak besar di laut utara Eropa, minyak mentah *Brent* ini memiliki gravitasi API sekitar 38.06 dan berat jenis sekitar 0.835 minyak jenis ini juga memiliki nilai kerapatan dan juga kandungan sulfur yang rendah. Kemudian WTI adalah jenis minyak yang berasal dari teluk Amerika Serikat, jenis minyak ini memiliki gravitasi API sekitar 39.6 dan juga memiliki kandungan sulfur yang rendah.

## **BAB IV**

### **METODOLOGI PENELITIAN**

#### **4.1. Populasi dan Sampel Penelitian**

Seluruh kumpulan data yang memiliki ciri-ciri atau karakteristik yang sama dalam suatu penelitian disebut dengan populasi. Populasi dari penelitian ini adalah semua data harga minyak mentah *West Texas Intermediate* (WTI). Sedangkan sampel yang digunakan adalah data harga minyak mentah (WTI) pada bulan Januari 2005 sampai dengan bulan Februari 2018.

#### **4.2. Variabel Penelitian**

Pada analisis GRNN dan FFNN yang akan dilakukan pada penelitian ini Terdapat satu variabel yaitu harga minyak mentah WTI.

#### **Harga Minyak Mentah *West Texas Intermediate* (WTI)**

Harga minyak mentah WTI merupakan salah satu acuan harga minyak mentah di seluruh dunia, termasuk Indonesia. WTI memiliki volume, produksi dan transparansi yang tinggi sehingga WTI dapat meminimalisir resiko dalam sektor energi. Nilai satuan yang digunakan oleh WTI ini adalah Barrel dan acuan nilai uang Dollar Amerika (Dollar/Barrel).

#### **4.3. Metode Pengumpulan Data**

Metode pengumpulan data yang digunakan dalam penelitian ini adalah metode sekunder, dimana data yang akan dianalisis tidak didapatkan langsung oleh peneliti melalui suatu pengamatan, namun data diperoleh dari sumber-sumber yang telah ada. Sumber data yang digunakan oleh peneliti yaitu *U.S. Energy Information Administration* ([www.eia.gov](http://www.eia.gov)).

#### **4.4. Metode Analisis Data**

Metode analisis data yang digunakan dalam penelitian ini adalah dua jenis metode dari cabang Neural Network, yang pertama yaitu analisis *Generalized*

*Regression Neural Network* (GRNN) dan metode yang kedua yaitu *Feed Forward Neural Network* (FFNN).

#### **4.5. Tahapan Analisis Data**

Terdapat tiga garis besar tahapan yang akan dilakukan pada penelitian ini yang pertama adalah *preprocessing* data, peramalan menggunakan metode GRNN dan yang terakhir adalah peramalan menggunakan metode FFNN.

##### **Tahap *Preprocessing* data**

Pada tahap ini intinya adalah mempersiapkan data yang akan di analisis dengan baik, pada tahap ini dilakukan beberapa hal seperti berikut :

1. Mempersiapkan data dalam *Microsoft Excel*.
2. Periksa *missing* data
3. Membagi data menjadi 2 bagian yaitu data pelatihan dan data uji, proporsi keduanya adalah 75% untuk data pelatihan dan 25% untuk data uji.

##### **Tahap Peramalan Menggunakan Metode GRNN**

Berikut ini Beberapa langkah yang dilakukan dalam peralamalan harga minyak mentah WTI menggunakan metode GRNN :

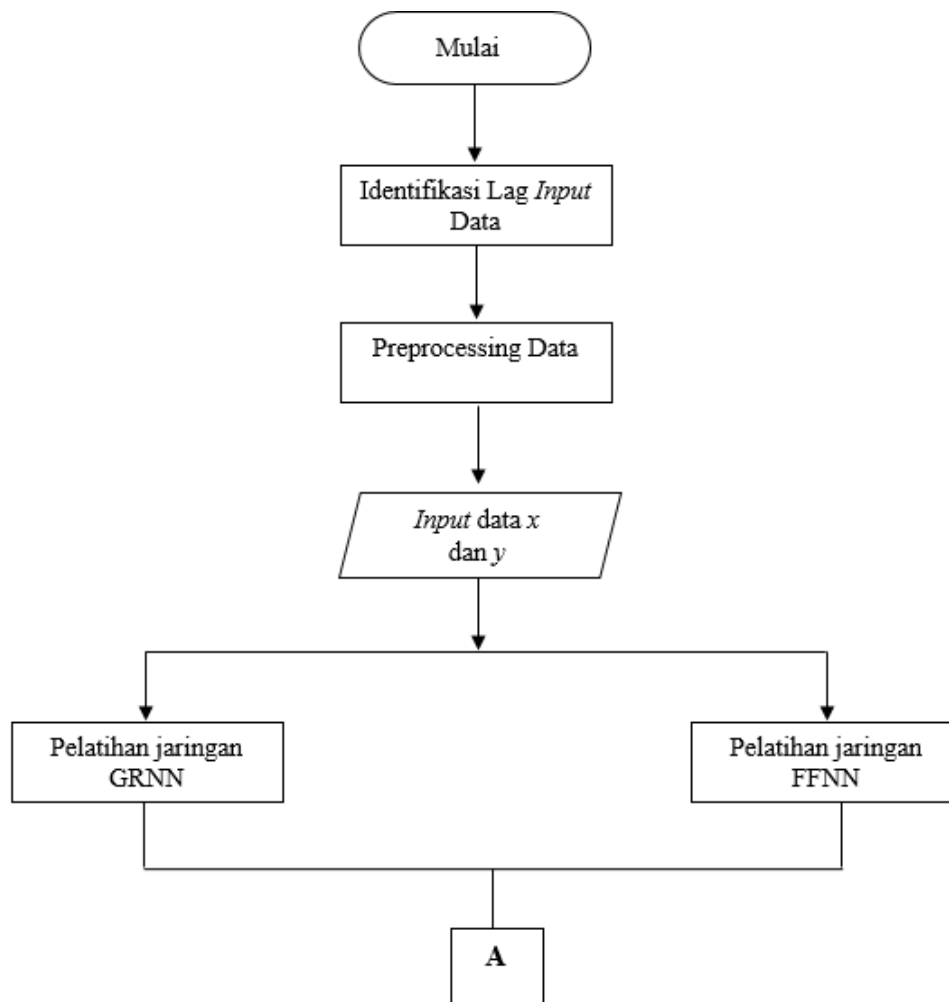
1. Menentukan variabel input yang optimal
2. Melakukan pelatihan pada data pelatihan. Pada tahap ini dilakukan beberapa pelatihan dengan nilai *spread* yang berbeda-beda sampai menemukan nilai *spread* yang sesuai dengan nilai *error* yang paling kecil.
3. Melakukan tahap pengujian menggunakan jaringan yang telah dibangun pada tahap pelatihan.
4. Melakukan peramalan menggunakan jaringan yang telah optimal berdasarkan tahap pelatihan dan pengujian.
5. Mendapatkan hasil peramalan dan melakukan pembahasan.

##### **Tahap Peramalan Menggunakan Metode FFNN**

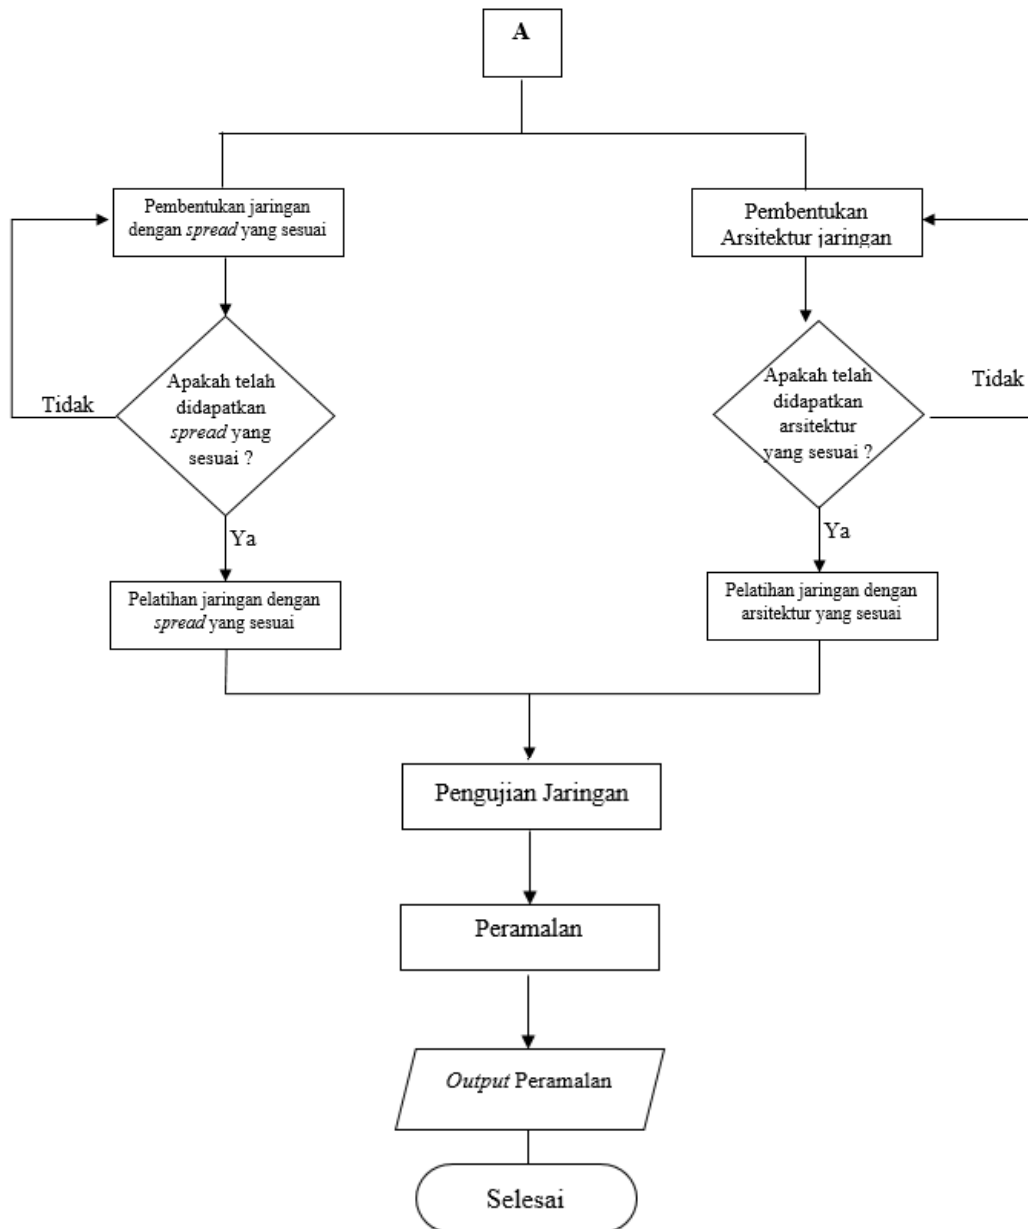
Kemudian selanjutnya berikut ini adalah langkah yang dilakukan dalam peralamalan harga minyak mentah WTI menggunakan metode FFNN :

1. Melakukan pelatihan menggunakan data pelatihan. Pada tahap ini dilakukan pembentukan arsitektur jaringan dengan menentukan banyaknya lapisan tersembunyi dan banyaknya neuron yang berbeda-beda sampai menemukan arsitektur yang sesuai dengan nilai *error* yang paling kecil.
2. Melakukan tahap pengujian menggunakan jaringan yang telah dibangun pada tahap pelatihan.
3. Melakukan peramalan menggunakan jaringan yang telah optimal berdasarkan tahap pelatihan dan pengujian.
4. Mendapatkan hasil peramalan dan melakukan pembahasan.

#### 4.6. Diagram Alur Penelitian Data








**Gambar 4.1.** Diagram Alur Penelitian

## BAB V

### HASIL DAN PEMBAHASAN

#### 5.1. Analisis Deskriptif


Harga minyak mentah dunia dari tahun ke tahun selalu mengalami perubahan, perubahan tersebut dipengaruhi oleh berbagai macam faktor. Pentingnya harga minyak mentah dunia sebagai indikator pergerakan ekonomi suatu bangsa bahkan ekonomi dunia membuat pantauan terhadap minyak mentah dunia ini sangatlah penting. Berikut ini adalah tabel yang menunjukkan nilai tertinggi dan terendah dari harga minyak mentah dunia yang didasarkan pada harga minyak mentah *West Texas Intermediate* (WTI) dalam kurun waktu 12 tahun terakhir.



**Gambar 5.1.** Grafik Harga Minyak Mentah WTI Tahun 2005-2017

Berdasarkan Gambar 5.1. merupakan gambaran mengenai harga minyak mentah WTI terendah dan tertinggi masing-masing pada tahun 2005 hingga tahun 2017. Harga minyak mentah tertinggi terjadi pada tahun 2008 yaitu sebesar 132,83 dollar/barrel, dimana pada tahun itu harga minyak mentah terendahnya adalah 41,34 dollar/barrel. Kemudian harga minyak mentah terendah yang pernah

terjadi adalah 29.78 dollar/barrel yaitu pada tahun 2016, dimana harga minyak tertinggi pada tahun tersebut adalah 52,62 dollar/barrel. Agar dapat melihat pergerakan harga minyak mentah secara lebih rinci (per bulan) akan disajikan plot *time series* berikut.




**Gambar 5.2.** Pergerakan Harga Minyak WTI Tahun 2005-2018

Pergerakan harga minyak mentah WTI pada Gambar 5.2. menunjukkan bahwa dalam waktu 13 tahun terakhir yaitu pada tahun 2005-2018 harga minyak mentah WTI mengalami kenaikan dan juga penurunan yang tidak konsisten atau dapat disebut juga berfluktuasi. Harga minyak mentah WTI ini pernah mengalami kenaikan yang drastis yaitu pada pertengahan tahun 2008, kemudian di akhir tahun tersebut harga minyak mentah kembali turun hingga pada kisaran harga 40 dollar/barrel dollar/barrel. Setelah itu berangsur-angsur naik kembali sampai pada bulan Maret 2011 hingga September 2014 harga minyak mentah ini cenderung tinggi pada kisaran 100 dollar/barrel. Kemudian pada periode Oktober 2014 sampai dengan April 2015 harga minyak mentah berangsur-angsur turun hingga mencapai kisaran 50 dollar/barrel.

## 5.2. Pendefinisian Model *Input Jaringan*

Identifikasi model jaringan ini berfungsi untuk menentukan variabel *input* yang akan digunakan dalam pemrosesan jaringan peramalan. Pemilihan variabel *input* ini dapat ditentukan menggunakan plot PACF, hal ini dikarenakan

karakteristik persamaan model pada peramalan menggunakan Artificial Neural Network sama dengan persamaan model pada proses Autoregresif (AR) dimana model AR menunjukkan pergerakan suatu variabel melalui variabel itu sendiri pada masa lampau atau dengan kata lain menjelaskan seberapa besar banyaknya nilai-nilai masa lalu yang mempengaruhi nilai saat ini (Rezzy, Hasbi dan Alan, 2015). Berikut ini adalah hasil plot PACF pada variabel harga minyak mentah WTI.



**Gambar 5.3.** Plot PACF Harga Minyak Mentah WTI

Berdasarkan Gambar 5.3. di atas dapat dilihat bahwa lag yang keluar adalah lag pertama dan kedua, oleh sebab itu dapat dikatakan bahwa  $X_t$  dipengaruhi oleh  $X_{t-1}$  dan  $X_{t-2}$ . Selanjutnya ditentukan *input* untuk peramalan harga minyak mentah WTI ini adalah  $X_1$  sebagai harga minyak mentah WTI lag 1 dan  $X_2$  sebagai harga minyak mentah WTI lag 2, dengan banyaknya data untuk masing-masing variabel menjadi 156 data.

Sebelum melakukan peramalan terdapat beberapa tahapan yang dilalui yaitu *preprocessing* data yang telah didapatkan dari *lag* input yang meliputi cek *missing* data dan juga partisi data. Tidak terdapat *missing* data pada ketiga variabel yang akan dianalisis yaitu harga minyak mentah WTI. Kemudian selanjutnya dilakukan

partisi data, partisi data ini digunakan untuk memisahkan data pelatihan jaringan dan juga data uji jaringan.

**Tabel 5.1.** Partisi Data

<b>Partisi Data</b>	<b>Persentase</b>	<b>Total</b>
Data Pelatihan	75%	117
Data Pengujian	25%	39
Total	100%	156

Data yang akan dimasukkan kedalam jaringan terlebih dahulu dinormalisasikan, data yang dinormalisasikan memberikan nilai *error* yang lebih minimum dengan kata lain bahwa jaringan akan dapat mengenali pola data dengan baik, seperti yang ditunjukkan pada tabel berikut.

**Tabel 5.2.** Perbandingan Normalisasi dan Denormalisasi

<b>Metode</b>	<b>MSE Normalisasi</b>	<b>MSE Tanpa Normalisasi</b>
GRNN	0,0013	1,8743
FFNN	0,0031	500,19

### **5.3. Peramalan Harga Minyak Mentah WTI Menggunakan Metode *Generalized Regression Neural Network* (GRNN)**

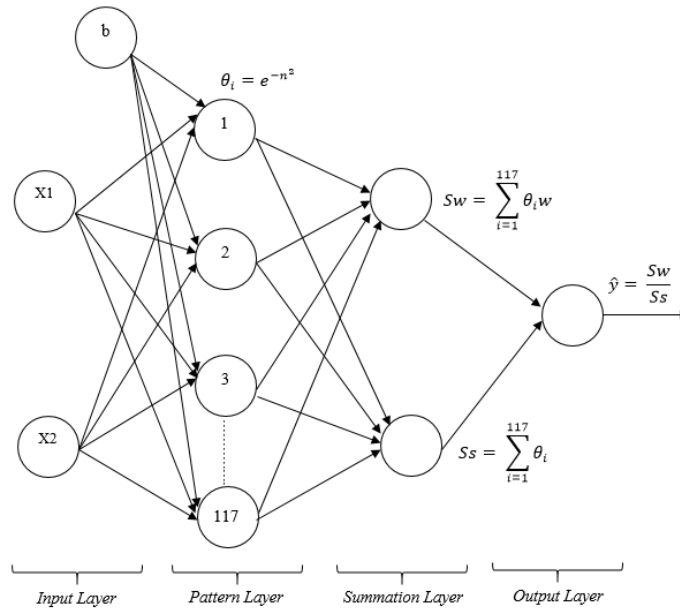
Peramalan menggunakan metode *Generalized Regression Neural Network* (GRNN) terdiri dari beberapa tahapan, yang pertama adalah tahap pelatihan, kemudian pengujian, setelah didapatkan pola jaringan yang sesuai maka dilanjutkan pada tahap peramalan.

#### **5.3.1. Pelatihan Jaringan GRNN**

Sebelum melakukan pelatihan pada jaringan, data *input* akan dinormalisasikan (Persamaan (3.38), halaman 26).

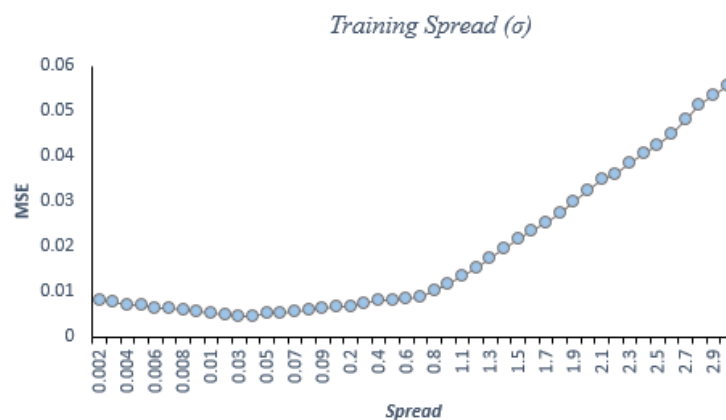
Jumlah neuron pada *pattern layer* adalah 117, hal ini sesuai dengan jumlah vektor *input* data pelatihan masing masing pada variabel  $X_1$  dan  $X_2$ . Berikut ini

adalah arsitektur jaringan yang terbentuk pada jaringan GRNN untuk tahap pelatihan.



**Gambar 5.4.** Arsitektur GRNN Peramalan Harga Minyak Mentah WTI

Jaringan GRNN memiliki satu parameter yaitu parameter *spread* ( $\sigma$ ) yang berfungsi sebagai parameter *smoothing* data. Untuk mendapatkan hasil jaringan yang maksimal, pada tahap pelatihan dilakukan beberapa percobaan pada parameter (*spread*), yang akan divisualisasikan dalam grafik berikut.




**Gambar 5.5.** Grafik Optimalisasi *Spread*

Pada tahap pelatihan ini, di uji coba menggunakan *spread* yang berbeda yaitu pada rentang 0,001 sampai dengan 3, seperti yang ditunjukkan pada Gambar

5.5., dimana dapat terlihat bahwa nilai MSE terendah terjadi pada saat pelatihan jaringan dengan nilai *spread* 0,03 yaitu 0,0013. Untuk itu, selanjutnya digunakan nilai *spread* 0,03 ini untuk pembentukan jaringan GRNN dalam peramalan harga minyak mentah WTI.

Fungsi aktivasi yang digunakan pada jaringan ini adalah fungsi aktivasi radial basis (Persamaan (3.11), halaman 16). Setelah fungsi aktivasi terbentuk, maka selanjutnya masuk pada *layer* atau lapisan selanjutnya yaitu *summation layer*, pada *layer* ini terdapat dua pemrosesan jaringan yang pertama adalah penjumlahan aritmatik terhadap fungsi aktivasi ( $S_s$ ) dan penjumlahan terboboti ( $S_w$ ), dimana bobot pada *layer* ini sama dengan nilai vektor target.

Kemudian masuk pada *output layer*, dimana *output* akan didapatkan dari nilai pembagian antara penjumlahan terboboti dan nilai penjumlahan fungsi aktivasi (Persamaan (3.26), halaman 22).  $\hat{y}$  adalah nilai keluaran dari *output layer* jaringan GRNN. Pada proses pelatihan, observasi pertama masing-masing variabel  $X_1$ ,  $X_2$  dan  $y$ . Untuk selanjutnya dilakukan proses yang sama sehingga didapatkan 117 *output* yang sesuai dengan jumlah vektor *input* variabel  $X$ . Berikut ini adalah grafik perbandingan antara data aktual dengan hasil prediksi pelatihan jaringan GRNN.

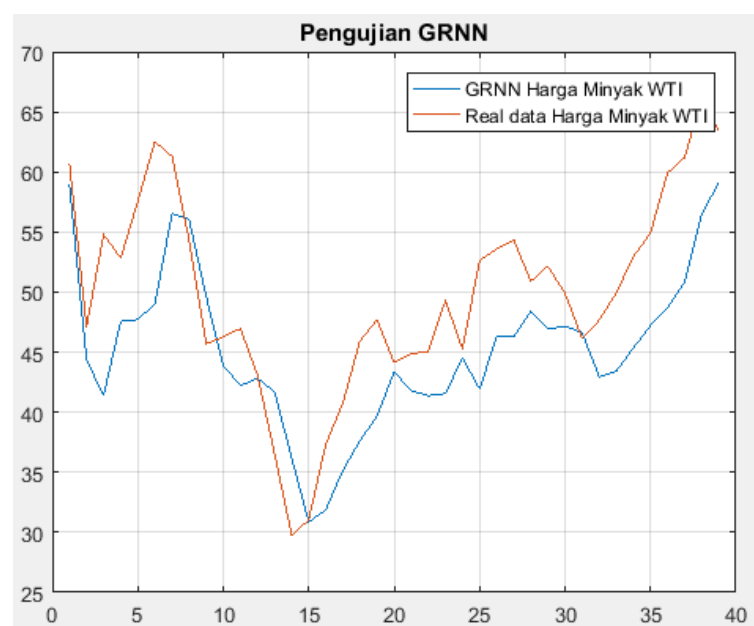


**Gambar 5.6.** Grafik Prediksi Data Pelatihan GRNN

Pada Gambar 14. garis biru menandakan harga minyak mentah WTI pada tahap pelatihan GRNN, sedangkan garis merah menandakan harga minyak mentah WTI pada kenyataannya. Dapat dilihat bahwa kenaikan dan penurunan harga minyak WTI yang diprediksi oleh jaringan GRNN hampir menyerupai data aktual atau data pada kenyataannya. Prediksi ini dilakukan dengan parameter *spread* 0,03 dan menghasilkan nilai MSE sebesar 0,00312 dan MAPE sebesar 3,03% yang artinya pelatihan jaringan GRNN ini memiliki tingkat akurasi sebesar 96,97%.

### 5.3.2. Pengujian Jaringan GRNN

Apabila suatu pelatihan jaringan telah usai, maka selanjutnya adalah tahap pengujian jaringan, pengujian jaringan ini bertujuan untuk mengetahui apakah jaringan yang telah terbentuk pada proses pelatihan telah handal untuk peramalan data minyak mentah WTI. Untuk itu maka selanjutnya dilakukan penginputan data pengujian yang berjumlah 39 data untuk masing-masing variabel  $X_1$ ,  $X_2$  dan  $y$ , pada jaringan GRNN yang telah terbentuk menggunakan *spread* 0,03. Berikut ini adalah perbandingan hasil prediksi dan harga minyak WTI aktual pada tahap pengujian menggunakan jaringan GRNN.



**Gambar 5.7.** Grafik Prediksi Data Pengujian GRNN



Dapat dilihat pada grafik pengujian jaringan GRNN pada Gambar 5.7. pola kenaikan dan penurunan harga minyak WTI yang diprediksi oleh jaringan GRNN hampir menyerupai data aktual atau data pada kenyataannya, meskipun rentang nilainya terlihat sedikit jauh. Prediksi ini dilakukan dengan parameter *spread* 0,03 dan menghasilkan nilai MSE sebesar 0,03312 dan MAPE sebesar 9,1% yang artinya pelatihan jaringan GRNN ini memiliki tingkat akurasi sebesar 90,9%.

### 5.3.3. Peramalan Minyak Mentah WTI Pada Jaringan GRNN

Kemudian setelah jaringan telah dirasa optimal, maka masuk pada tahap peramalan. Peramalan menggunakan GRNN ini cenderung lebih cepat, selain karena jaringan ini memiliki bentuk yang baku pada jumlah neuronnya, namun juga karena tidak memiliki iterasi yang besar pada pengoptimalan bobot-bobotnya, karena bobot yang digunakan juga di atur sebagai *input* data untuk bobot pada *pattern layer*, dan target untuk bobot pada *output layer*. Tahap peramalan harga minyak mentah WTI pada jaringan GRNN dibentuk pada *spread* 0,03 yang telah melalui tahap pelatihan dan pengujian.

Peramalan dilakukan dengan menggunakan *input*  $X_{t-1}$  dan  $X_{t-2}$  masing-masing merupakan data bulan Januari dan Februari 2018, dan menggunakan informasi bobot yang telah didapatkan pada tahap pelatihan. Langkah pertama yang dilakukan untuk peramalan ini adalah mencari jarak antara data *input* dan bobot dengan menggunakan jarak Euclidian (Persamaan (3.22), halaman 21).

$$D_1 = \sqrt{(0,3537 - 0,0380)^2 + (0,3268 - 0,0178)^2} = 0,4417$$

$$D_2 = \sqrt{(0,3537 - 0,1049)^2 + (0,3268 - 0,0380)^2} = 0,3811$$

$$D_3 = \sqrt{(0,3537 - 0,1017)^2 + (0,3268 - 0,1049)^2} = 0,3358$$

•  
•  
•

$$D_{117} = \sqrt{(0,3537 - 0,4890)^2 + (0,3268 - 0,5958)^2} = 0,3011$$

Kemudian karna nilai *spread* telah ditentukan yaitu sebesar 0,03 maka nilai bobot biasanya bernilai  $0,8326/0,03 = 27,75$ . Dengan demikian, maka fungsi aktivasinya adalah :

$$\theta_1 = e^{-(27,75 \cdot 0,4417)^2} = 5,389 \cdot 10^{-66}$$

$$\theta_2 = e^{-(27,75 \cdot 0,3811)^2} = 2,540 \cdot 10^{-49}$$

$$\theta_3 = e^{-(27,75 \cdot 0,3358)^2} = 1,913 \cdot 10^{-38}$$

•

•

•

$$\theta_{117} = e^{(27,75 \cdot 0,3011)^2} = 4,663 \cdot 10^{-31}$$

Nilai aktivasi yang didapatkan digunakan untuk menghitung keluaran pada *summation layer*, yaitu penjumlahan fungsi aktivasi ( $S_s$ ) dan penjumlahan fungsi aktivasi terboboti ( $S_w$ ).

$$S_s = \sum_{i=1}^{117} \theta_i$$

$$\begin{aligned} S_s &= 5,389 \cdot 10^{-66} + 2,540 \cdot 10^{-49} + 1,913 \cdot 10^{-38} + \dots + 4,663 \cdot 10^{-31} \\ &= 3,7015 \end{aligned}$$

dan,

$$S_w = \sum_{i=1}^{117} \theta_i w_i$$

$$\begin{aligned} S_w &= (5,389 \cdot 10^{-66} \times 0,1049) + (2,540 \cdot 10^{-49} \times 0,2946) + \\ &\quad (1,913 \cdot 10^{-38} \times 0,3400 + \dots + 4,663 \cdot 10^{-31} \times 0,3897) \end{aligned}$$

$$S_w = 1,2915$$

Beralih pada *layer* selanjutnya yaitu *output layer* yang merupakan hasil pembagian dari penjumlahan fungsi aktivasi ( $S_s$ ) dan penjumlahan fungsi aktivasi terboboti ( $S_w$ ).

$$\hat{y}_t = \frac{S_w}{S_s} = \frac{1,2915}{3,7015} = 0,3498$$

Nilai  $\hat{y}_t$  yang didapatkan masih dalam bentuk normalisasi, untuk itu selanjutnya dilakukan denormalisasi agar data berada dalam kondisi aktual (Perasamaan (3.39), halaman 27).

Hasil peramalan harga minyak mentah WTI pada bulan Maret setelah di denormalisasikan adalah 62,09. Kemudian dilakukan langkah yang sama untuk meramalkan harga minyak mentah WTI pada periode selanjutnya. Jaringan ini telah menghasilkan nilai peramalan harga minyak mentah WTI untuk 6 periode selanjutnya yang akan ditunjukkan pada tabel berikut.

**Tabel 5.3.** Hasil Peramalan Harga Minyak GRNN

<b>Periode</b>	<b>Harga Minyak Mentah WTI (Dollar/Barrel)</b>
Maret 2018	62,09
April 2018	61,28
Mei 2018	61,85
Juni 2018	61,32
Juli 2018	61,53
Agustus 2018	61,12

Seperti yang dapat dilihat pada Tabel 5.3 di atas, harga minyak mentah WTI pada bulan Maret 2018 diperkirakan sebesar 62,09 dollar/barrel, kemudian pada bulan April turun menjadi 61,28 dollar/barrel, selanjutnya pada bulan Mei naik kembali menjadi 61,85 dollar/barrel. Pada bulan Juni harga minyak mentah WTI diperkirakan sebesar 61,32 dollar/barrel kemudian bulan Juli naik menjadi 61,53 dollar/barrel dan pada bulan Agustus turun kembali menjadi 61,12 dollar/barrel.

#### **5.4. Peramalan Harga Minyak Mentah WTI Menggunakan Metode *Feed Forward Neural Network* (FFNN)**

Jaringan syaraf tiruan model *Feed Forward Neural Network* (FFNN) yang akan digunakan pada penelitian kali ini menggunakan algoritma *Backpropagation*, yang artinya pada tahapan pemrosesannya akan ada dua fase. Fase I adalah fase *feed forward*, dimana pada fase ini jaringan akan berjalan maju mulai dari *input layer* hingga *output layer* dan membawa informasi bobot secara random (acak). Kemudian selanjutnya setelah fase I selesai dilakukan dan didapatkan *output* maka jaringan akan meneruskan pemrosesan ke fase II yaitu fase *backpropagation*, pada fase ini jaringan akan berjalan mundur mulai dari *output layer* sampai ke *input layer* dengan menentukan faktor koreksi sebagai pengoptimalan bobot yang digunakan jaringan.

Pada jaringan FFNN ini juga terdapat tahapan pelatihan dan juga pengujian, oleh sebab itu maka data dipartisi menjadi dua bagian, Seperti pada jaringan GRNN data untuk pelatihan adalah 75% dari data yaitu sebanyak 117 data, dan data yang digunakan pada tahap pengujian sebesar 25% yaitu 39 data. Adapun tahapan yang dilakukan pada jaringan FFNN ini adalah normalisasi data, tahap pelatihan dengan fungsi aktivasi dan tahap pengujian serta peramalan.

##### **5.4.1. Arsitektur Jaringan FFNN**

Pada dasarnya jaringan FFNN terdiri dari 3 lapisan/*layer*, yang pertama yaitu *input layer* yang berfungsi untuk masukan pada jaringan, *layer* yang selanjutnya adalah *hidden layer*. Sedangkan fungsi aktivasi yang digunakan untuk transfer sinyal pada *hidden layer* ini akan di uji coba menggunakan dua fungsi aktivasi yang pertama adalah fungsi aktivasi sigmoid biner dan yang kedua adalah fungsi aktivasi sigmoid bipolar. Kemudian untuk transfer pada *output layer* digunakan fungsi aktivasi identitas. Selain jumlah *hidden layer*, terdapat beberapa hal yang sangat mempengaruhi keoptimalan jaringan, diantaranya yaitu jumlah neuron pada *hidden layer*, *learning rate* ( $\alpha$ ) dan juga momentum ( $\beta$ ). Oleh sebab

itu dilakukan beberapa uji untuk menentukan jaringan yang optimal dengan beberapa percobaan dengan jumlah neuron maksimal.

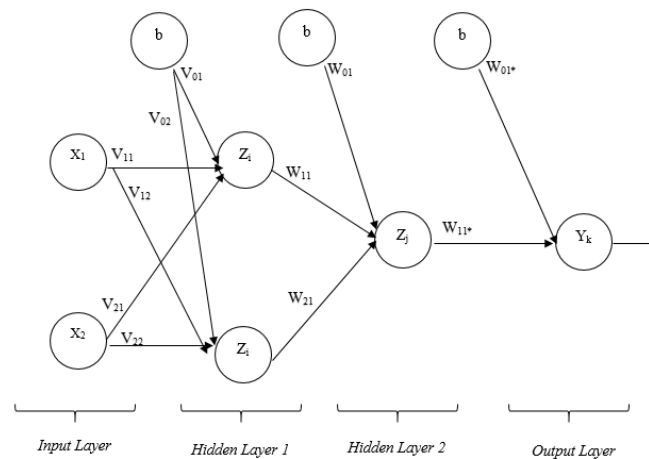
Jaringan FFNN yang akan dibentuk pada penelitian kali ini memiliki dua variabel *input* yaitu  $X_1$  dan  $X_2$ , yang berarti memberikan jumlah neuron pada *hidden layer* maksimal adalah  $2^{(2-1)} = 2$  (Persamaan(3.27), halaman 23). Jaringan FFNN pada penelitian ini menggunakan dua parameter yaitu *learning rate* dan momentum, nilai *learning rate* dan momentum yang digunakan merupakan nilai basis pada jaringan FFNN yaitu 0,01 dan 0,9. Berikut ini adalah hasil percobaan *trial and error* arsitektur jaringan FFNN.

**Tabel 5.4.** Pembentukan Arsitektur Jaringan FFNN

Jumlah <i>Hidden Layer</i>	Jumlah Neuron	Fungsi Aktivasi	
		Sigmoid Bipolar	Sigmoid Biner
1	1	0.0034	0.0381
1	2	0.0040	0.0377
2	1	0.0035	0.0034
	2	0.0044	0.0050
2	1	0.0033	0.00310
	2	0.0034	0.00312

Tabel 5.4. menunjukkan bahwa MSE terendah berada pada percobaan jaringan FFNN didapatkan pada jaringan yang memiliki dua *hidden layer*, dengan jumlah neuron pada *hidden layer* pertama adalah satu dan neuron pada *hidden layer* kedua adalah dua.

Dalam struktur jaringan FFNN, pada *input layer* terdapat 2 nilai *input*, kemudian untuk menuju ke *layer* selanjutnya yaitu *hidden layer*, diikuti oleh bobot *input* jaringan dan bobot bias jaringan pada masing-masing neuron yang disimbolkan dengan  $V_{ji}$  dan  $V_{0j}$ , Kemudian untuk keluaran pada *hidden layer* menuju ke *output layer* diikuti pula dengan bobot keluaran ( $W_{k,ij}$ ) dan bobot bias ( $W_{0k}$ ).



**Gambar 5.8.** Struktur Jaringan FFNN


#### 5.4.2. Pelatihan Jaringan FFNN

Pelatihan jaringan FFNN dilakukan dengan menggunakan dua *hidden layer* dan jumlah neuron yang paling kecil MSEnya yaitu 2 neuron. Tahap pertama yang dilakukan pada proses pelatihan ini adalah *input* data pelatihan yang sudah dipartisi sebelumnya yaitu 117 data. Setelah data masuk pada jaringan selanjutnya data tersebut akan dinormalisasikan pada rentang [0 1] agar sesuai dengan fungsi aktivasi yang digunakan yaitu fungsi aktivasi sigmoid biner menggunakan (persamaan (3.8), halaman 14).

Data yang telah dinormalisasikan selanjutnya telah siap untuk diproses pada fase I yaitu fase *feed forward*.

##### **Fase I : Feed Forward**

Pada pemrosesan input layer menuju hidden layer masing-masing variabel input akan memiliki bobot yang di *set* secara random. Karena pemilihan bobot ini dilakukan menggunakan sistem random, maka diperlukan suatu keakuratan apabila suatu jaringan yang dilatih akan terus memberikan suatu bobot random yang konstan. Berikut ini adalah susunan random bobot FFNN yang telah di coba selama 10 kali pemrosesan jaringan.



**Gambar 5.9.** Grafik Bobot Random Jaringan FFNN

Berdasarkan grafik bobot yang telah ditampilkan pada Gambar 5.9. diketahui bahwa bobot yang dihasilkan oleh jaringan secara random telah membentuk suatu nilai yang cenderung konstan bergerak pada angka-angka kecil. Selain bobot pada variabel *input*, bobot bias untuk masing-masing neuron pada *hidden layer* juga didapatkan dengan cara random, berikut ini adalah bobot-bobot yang didapatkan pada *input layer*.

**Tabel 5.5.** Bobot Awal *Input Layer*

Variabel	$j \backslash i$	$V_{ij}$	
		1	2
X1	1	2,5535	-3,0265
X2	2	2,7740	2,8258

**Tabel 5.6.** Bobot Bias Awal *Input Layer*

Variabel	$j \backslash i$	$V_{0j}$
X1	1	-3,9598
X2	2	3,9598

Selanjutnya setelah didapatkan nilai *input* beserta bobotnya pemrosesan masuk pada *hidden layer*. Nilai *input* dan bobot ini digunakan untuk menghitung keluaran disetiap neuron pada *hidden layer* dengan menggunakan (Persamaan (3.29), halaman 24). Untuk dapat mengeluarkan *output* pada *hidden layer* ini diperlukan suatu fungsi aktivasi. Pada jaringan FFNN ini digunakan fungsi

aktivasi sigmoid biner yang diformulasikan pada (Persamaan (3.28), halaman 24). Dalam memproses keluaran jaringan dari *hidden layer* ke *output layer* ini juga digunakan bobot yang di dapatkan secara random pada bobot keluaran *hidden layer* pertama dan *hidden layer* kedua serta juga biasanya.

**Tabel 5.7.** Bobot Neuron *Hidden Layer Pertama*

$j \backslash i$	$W_{ij}$
1	0,2647
2	0,8049

**Tabel 5.8.** Bobot Bias Neuron *Hidden Layer Pertama*

$j \backslash i$	$W_{0j}$
1	1,7851

Setelah keluaran pada *hidden layer* pertama, maka proses yang sama dilakukan untuk mendapatkan keluaran *hidden layer* kedua. Kemudian didapatkan keluaran pada *hidden layer* kedua, maka selanjutnya jaringan akan memproses data ke *output layer*, dengan bobot seperti berikut.

**Tabel 5.9.** Bobot Neuron *Hidden Layer Kedua*

$j \backslash i$	$W_{jk}$
1	0,9143

**Tabel 5.10.** Bobot Bias Neuron *Hidden Layer Kedua*

$j \backslash i$	$W_{0k}$
1	0,9143

Proses ini menghasilkan nilai prediksi harga minyak mentah WTI pada bulan Januari 2005 yang didapatkan pada fase I data 1, kemudian dilakukan proses yang sama untuk menghasilkan nilai prediksi data selanjutnya sampai dengan data ke 117 pada iterasi terakhir.



### **Fase II : Backpropagation**

Langkah pertama yang dilakukan pada fase II ini adalah mencari faktor kesalahan pada setiap *output* yang dihasilkan pada fase I ( $\delta$ ). Setelah didapatkan nilai faktor kesalahan pada masing-masing *output* ( $Y_k$ ), selanjutnya nilai ini digunakan untuk menghitung suku perubahan bobot ( $\Delta W$ ) dengan laju pembelajaran  $\alpha = 0,01$ . Suku perubahan bobot yang telah didapatkan kemudian digunakan untuk menghitung bobot baru pada koreksi bobot  $Y_k$  pertama iterasi pertama.

Langkah yang sama dilakukan untuk mencari bobot baru pada *hidden layer* pertama. Suku perubahan bobot yang telah didapatkan kemudian digunakan untuk menghitung bobot baru pada koreksi bobot  $Y_k$  pertama iterasi pertama. Setelah didapatkan bobot keluaran pada *hidden layer* dan juga bobot biasnya, langkah selanjutnya adalah menghitung faktor kesalahan pada pemrosesan *hidden layer* yang menuju ke *input layer*. Setelah didapatkan nilai faktor kesalahan pada *hidden layer* ( $\delta_j$ ) selanjutnya nilai ini digunakan untuk menghitung suku perubahan bobot ( $\Delta V$ ).

Bobot-bobot baru yang didapatkan adalah bobot untuk observasi pertama, bobot ini akan terus diperbaharui dengan menggunakan nilai observasi berikutnya dan dihentikan saat iterasi telah mencapai bobot yang optimal, Berikut ini adalah bobot-bobot optimal yang telah didapatkan pada fase II,

**Tabel 5.11.** Bobot Akhir *Input Layer*

Variabel	$j \backslash i$	$V_{ij}$	
		1	2
X1	1	2,7172	-1,8836
X2	2	-2,3078	-0,2591

**Tabel 5.12.** Bobot Bias Akhir *Input Layer*

Variabel	$j \backslash i$	$V_{0j}$
X1	1	-1,8448
X2	2	-1,8006

Kemudian bobot-bobot akhir optimal untuk *hidden layer*nya adalah sebagai berikut :

**Tabel 5.13.** Bobot Akhir Neuron *Hidden Layer Pertama*

$j \backslash i$	$W_{ij}$
1	-4,2654
2	3,9097

**Tabel 5.14.** Bobot Bias Akhir Neuron *Hidden Layer Pertama*

$j \backslash i$	$W_{0j}$
1	0,4831


**Tabel 5.15.** Bobot Akhir Neuron *Hidden Layer Kedua*

$j \backslash i$	$W_{jk}$
1	-2,5268

**Tabel 5.16.** Bobot Bias Akhir Neuron *Hidden Layer Kedua*

$j \backslash i$	$W_{0k}$
1	1,5756

Bobot-bobot akhir yang telah optimal tersebut selanjutnya diterapkan pada jaringan FFNN dan didapatkan nilai prediksi pada tahap pelatihan ini yang akan digambarkan pada grafik berikut.



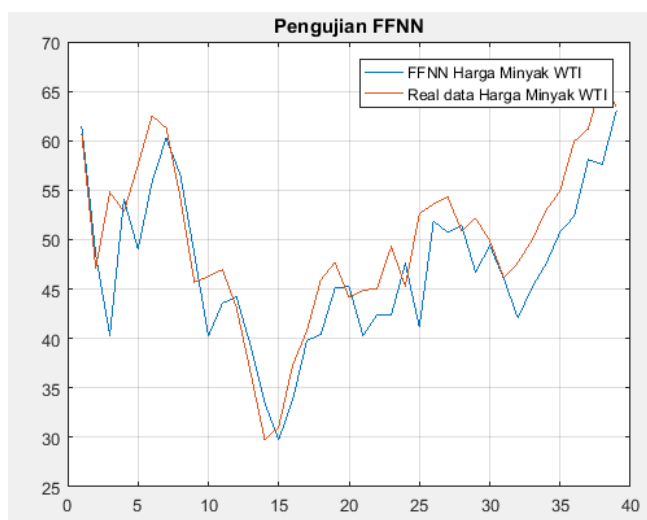
**Gambar 5.10.** Grafik Prediksi Data Pelatihan FFNN

Pada Gambar 5.10., garis biru menandakan harga minyak mentah WTI pada tahap pelatihan FFNN, sedangkan garis merah menandakan harga minyak mentah WTI pada kenyataannya. Dapat dilihat bahwa kenaikan dan penurunan harga minyak WTI yang diprediksi oleh jaringan FFNN hampir menyerupai data aktual atau data pada kenyataannya. Prediksi ini dilakukan dengan dengan dua *hidden layer*, dan menghasilkan nilai MSE sebesar 0,00310, dan MAPE sebesar 5,41% yang artinya pelatihan jaringan FFNN ini memiliki tingkat akurasi sebesar 94,59%.

#### 5.4.3. Pengujian Jaringan FFNN

Pelatihan jaringan FFNN telah selesai diproses, selanjutnya masuk pada tahap pengujian jaringan, sama seperti jaringan GRNN maupun model *neural network* pada umumnya, pengujian jaringan ini bertujuan untuk mengetahui apakah jaringan yang telah terbentuk pada proses pelatihan telah handal untuk mengenali data baru yang dimasukkan pada jaringan yang telah dilatih. Dengan menggunakan jaringan pelatihan FFNN, data pelatihan dimasukkan ke dalam jaringan melalui *input layer*, tahapan yang dilalui sama dengan tahapan pada pelatihan jaringan, hanya saja yang membedakan adalah jaringan telah menyimpan pemrosesan pelatihan jaringan sebelumnya baik bobot pada nilai *input* maupun bobot bias. Langkah selanjutnya adalah menghitung keluaran *input*

*layer* ke *hidden layer*, seperti yang telah dilakukan pada proses pelatihan jaringan. Kemudian diteruskan ke *output* jaringan sehingga menghasilkan nilai prediksi minyak mentah WTI oleh jaringan FFNN pada pengujian jaringan yang digambarkan pada grafik berikut.



**Gambar 5.11.** Grafik Prediksi Data Pengujian FFNN

Dapat dilihat pada grafik pengujian jaringan FFNN pada Gambar 20., pola kenaikan dan penurunan harga minyak WTI yang diprediksi oleh jaringan FFNN memang tidak sama persis seperti data aktualnya, namun hampir menyerupai data aktual atau data pada kenyataannya, Prediksi menghasilkan nilai MSE sebesar 0,0185 dan MAPE sebesar 9,96% yang artinya pengujian jaringan FFNN ini memiliki tingkat akurasi sebesar 90,40%,

#### 5.4.4. Peramalan Minyak Mentah WTI Pada Jaringan FFNN

Setelah melewati proses pelatihan dan juga pengujian sehingga menghasilkan jaringan yang optimal, maka masuk pada tahap peramalan. Peramalan menggunakan FFNN juga tidak memiliki iterasi yang besar pada pengenalan pola datanya. Tahap peramalan harga minyak mentah WTI pada jaringan FFNN dibentuk dengan menggunakan dua *hidden layer*, yang telah melalui tahap pelatihan dan pengujian.

Nilai *input* dan bobot ini digunakan untuk menghitung keluaran disetiap neuron pada *hidden layer* dengan menggunakan (Persamaan (3.29), halaman 24).

Untuk dapat mengeluarkan *output* pada *hidden layer* ini diperlukan suatu fungsi aktivasi. Pada jaringan FFNN ini digunakan fungsi aktivasi sigmoid biner yang diformulasikan pada (Persamaan (3.28), halaman 24). Setelah keluaran pada *hidden layer* pertama, maka proses yang sama dilakukan untuk mendapatkan keluaran *hidden layer* kedua, kemudian didapatkan output peramalan harga minyak mentah WTI pada bulan Maret 2018 (Persamaan (3.30), halaman 25).

Hasil peramalan pada bulan Maret 2018 adalah 0,3826 yang kemudian akan dinormalisasikan menjadi 63,84 dollar/barrel. Untuk peramalan bulan selanjutnya dilakukan proses yang sama dengan menggunakan *input* yang berurutan pada periode sebelumnya. Berikut ini adalah hasil peramalan harga minyak mentah WTI untuk 6 periode selanjutnya pada iterasi terakhir yang akan ditunjukkan pada tabel berikut :

**Tabel 5.15.** Hasil Peramalan Harga Minyak FFNN

Periode	Harga Minyak Mentah WTI (Dollar/Barrel)
Maret 2018	63,84
April 2018	61,79
Mei 2018	63,84
Juni 2018	65,62
Juli 2018	60,44
Agustus 2018	68,83

Seperti yang dapat dilihat pada Tabel 5.15. di atas, harga minyak mentah WTI pada bulan Maret 2018 diperkirakan sebesar 63,84 dollar/barrel, kemudian pada bulan April turun menjadi 61,79 dollar/barrel, selanjutnya pada bulan Mei naik kembali menjadi 63,84 dollar/barrel. Pada bulan Juni harga minyak mentah WTI diperkirakan sebesar 65,62 dollar/barel kemudian bulan Juli turun menjadi 60,44 dollar/barrel dan pada bulan Agustus naik kembali menjadi 68,83 dollar/barrel.

## BAB VI

### KESIMPULAN DAN SARAN

#### 6.1. Kesimpulan

Berdasarkan penelitian dan juga pembahasan yang telah dilakukan dalam peramalan harga minyak mentah WTI menggunakan metode *Generalized Regression Neural Network* (GRNN) dan juga *Feed Forward Neuwal Network* (FFNN), berikut ini adalah beberapa kesimpulan yang didapatkan :

1. Dalam peramalan harga minyak mentah WTI dengan menggunakan metode GRNN, diperoleh model seperti berikut :

$$\hat{Y}_t = \frac{S_w}{S_s} = \frac{\sum_{i=1}^{117} W_i \times \theta_i}{\sum_{i=1}^{117} \theta_i}$$
$$\frac{\sum_{i=1}^{117} W_i \times e^{-\left(b \sqrt{(X_{t-1}-v_{ij})^2+(X_{t-2}-v_{ij})^2}\right)}}{\sum_{i=1}^{117} e^{-\left(b \sqrt{(X_{t-1}-v_{ij})^2+(X_{t-2}-v_{ij})^2}\right)}}$$

Kemudian untuk FFNN didapatkan model pada peramalan harga minyak mentah WTI sebagai berikut :

$$\hat{Y}_t = 1,5756 + ((1,6919 \times Z_{jk}) + (-0,3839 \times Z_{jk}))$$

dengan  $Z_{jk}$  merupakan keluaran dari *hidden layer* menuju *output layer*.

$$Z_{jk} = \frac{1}{1 + e^{-\left(v_{0j} + ((X_{t-1} \times v_{ij}) + (X_{t-2} \times v_{ij}))\right)}}$$

2. Berdasarkan nilai MSE dan juga MAPE baik pelatihan maupun pengujian, keduanya menunjukkan bahwa metode GRNN lebih baik untuk meramalkan harga minyak mentah WTI dengan akurasi yang dihasilkan berdasarkan nilai MAPE sebesar 90,9%.

## 6.2. Saran

Untuk perbaikan penelitian menggunakan GRNN dan FFNN kedepannya, berikut ini adalah beberapa saran yang dapat dipertimbangkan :

1. Agar jaringan dapat mengenali pola data semakin baik maka sebaiknya ditambahkan jumlah data yang akan diramalkan baik dari segi pelatihan maupun pengujian.
2. Diperlukanya analisis faktor-faktor yang dapat mempengaruhi harga minyak mentah WTI agar peramalan harga minyak mentah WTI yang didapatkan semakin akurat.
3. Sebaiknya dilakukan beberapa uji partisi data pada data harga minyak mentah WTI yang lebih banyak, karena partisi data ini sangat memegang peran yang penting pada metode jaringan syaraf tiruan.

## DAFTAR PUSTAKA

- Adnyani, L.P. 2012. *General Regression Neural Network (GRNN)*. Yogyakarta. Universitas Gajah Mada.
- Ansofino, J., dkk. 2016. *Ekonometrika*. Yogyakarta. Deepublish.
- Baum, E. dan Haussler, D. 1989. *What Size Net Gives Valid Generalization?*. *Neural Computation*. Vol. 1(1). 151-160.
- BPS. 2015. *Pertumbuhan Ekonomi Indonesia*. Tersedia di [www.bps.go.id](http://www.bps.go.id) di akses pada 17 Februari 2018 Pukul 19.00 WIB
- Caraka, R. E., dkk. 2015. *Pemodelan General Regression Neural Network (GRNN) pada Data Return Indeks Harga Saham Euro 50*. *Jurnal Gaussian*. Vol 4 (2).
- Fausset, L.. 1994. *Fundamentals Of Neural Networks*. Englewood Clifft. New Jersey. PTR Prentice-Hall Inc
- Hanke, J. E. dan Wichers D.W. 2005. *Bussiness Forecasting Eight Edition* .New Jersey . Pearson Prentice Hall.
- Harliansyah, R. dan Jamilatuzzahro. 2017. *Feed Forward Neural Networks for Forecasting Indonesia Exchange Composite Index*. *Journal Mathematics , Statistics and IOperational Research*. Vol. 4 (1).
- Hermawan, A. 2006. *Jaringan Syaraf Tiruan : Teori dan Aplikasi*. Andi Offset. Yogyakarta.
- Juanda, B. dan Junaidi. 2012. *Ekonometrika Deret Waktu Teori dan Aplikasi*. Bogor . IPB Press.
- Kusumadewi, F. 2014. *Peramalan Harga Emas Menggunakan Feedforward Neural Network dengan Algoritma Backpropagation*. Yogyakarta. Universitas Negeri Yogyakarta.
- Kristanto, A. 2004. *Jaringan Saraf Tiruan*. Yogyakarta . Gava Media.



- Lin, C. T. dan Lee G. 1996. *Neuro Fuzzy Systems*. New Jersey. Prentice-Hall.
- Orr, M. J. L. 1996. *Introduction to Radial Basis Function Neural Networks*.  
Edinburgh: University of Edinburgh.
- Rutkowski, L. 2004. *New Soft Computing Techniques for System Modelling, Pattern Classification and Image Processing*. New York. Springer
- Sanusi, B. 1984. *Indonesia Dalam Dunia Perminyakan*. Jakarta: Penerbit Universitas Indonesia.
- Siang, J.J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Penerbit Andi. Yogyakarta.
- Specht, D.F. 1991. *A Generalized Regression Neural Network*. IEEE Transactions on Neural Networks. vol.2, 1991 568-576.
- Stamnes, K. dan Jakob J. S. 2015. *Radiative Transfer in Coupled Environmental Systems*. Germany. Wiley-VCH
- Subagyo, P. 1986. *Forecasting Konsep dan aplikasi*. Yogyakarta: BPPE UGM.
- Supriyanto, E. 2004. *Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Harga Saham*. Bandung. Universitas Komputer Indonesia.
- Thanaki, J. 2017. *Python Natural Language Processing*. Packt Publishing Ltd. Birmingham
- Ukil, A. 2007. *Intelligent Systems and Signal Processing in Power Engineering*. New York . Springer
- U.S. Energy Information Administration. *Spot Prices for Crude Oil and Petroleum Products – EIA*. Tersedia di [www.eia.gov](http://www.eia.gov) diakses pada 02 Februari 2018 pukul 13.00 WIB
- Wasserman P.D. 1993. *Advanced Methods in Neural Computing*. New York: Van Nostrand Reinhold. pp. 155-61. dan pp. 35-55

Yeung D. S., dkk. 1998. *Sensitivity Analysis of Neural Networks*. New York .  
Springer.

# LAMPIRAN

**Lampiran 1 : Data Harga Minyak Mentah WTI**

No.	Waktu	Harga Minyak (US\$/Barrel)
1	Jan-05	42,97
2	Feb-05	44,82
3	Mar-05	50,94
4	Apr-05	50,64
5	Mei-05	47,83
6	Jun-05	53,89
7	Jul-05	56,37
8	Agu-05	61,89
9	Sep-05	61,69
10	Okt-05	58,19
11	Nov-05	55,04
12	Des-05	56,43
13	Jan-06	62,46
14	Feb-06	59,7
15	Mar-06	60,93
16	Apr-06	67,97
17	Mei-06	68,68
18	Jun-06	68,29
19	Jul-06	72,45
20	Agu-06	71,81
21	Sep-06	62,12
22	Okt-06	57,91
23	Nov-06	58,14
24	Des-06	60,99
25	Jan-07	53,52
26	Feb-07	57,56
27	Mar-07	60,6
28	Apr-07	65,06
29	Mei-07	65,16
30	Jun-07	68,19
31	Jul-07	73,6
32	Agu-07	70,13
33	Sep-07	76,76
34	Okt-07	81,97
35	Nov-07	91,34
36	Des-07	89,52

No.	Waktu	Harga Minyak (US\$/Barrel)
37	Jan-08	90,69
38	Feb-08	93,39
39	Mar-08	101,84
40	Apr-08	108,76
41	Mei-08	122,63
42	Jun-08	131,52
43	Jul-08	132,83
44	Agu-08	114,57
45	Sep-08	99,66
46	Okt-08	72,69
47	Nov-08	53,97
48	Des-08	41,34
49	Jan-09	43,86
50	Feb-09	41,84
51	Mar-09	46,65
52	Apr-09	50,28
53	Mei-09	58,15
54	Jun-09	69,15
55	Jul-09	64,67
56	Agu-09	71,63
57	Sep-09	68,35
58	Okt-09	74,08
59	Nov-09	77,55
60	Des-09	74,88
61	Jan-10	77,12
62	Feb-10	74,76
63	Mar-10	79,3
64	Apr-10	84,18
65	Mei-10	75,62
66	Jun-10	74,73
67	Jul-10	74,58
68	Agu-10	75,83
69	Sep-10	76,12
70	Okt-10	81,72
71	Nov-10	84,53
72	Des-10	90,01

No.	Waktu	Harga Minyak (US\$/Barrel)
73	Jan-11	92,69
74	Feb-11	97,91
75	Mar-11	108,65
76	Apr-11	116,24
77	Mei-11	108,07
78	Jun-11	105,85
79	Jul-11	107,92
80	Agu-11	100,49
81	Sep-11	100,82
82	Okt-11	99,85
83	Nov-11	105,41
84	Des-11	104,23
85	Jan-12	107,07
86	Feb-12	112,69
87	Mar-12	117,79
88	Apr-12	113,67
89	Mei-12	104,09
90	Jun-12	90,73
91	Jul-12	96,75
92	Agu-12	105,27
93	Sep-12	106,28
94	Okt-12	103,41
95	Nov-12	101,17
96	Des-12	101,19
97	Jan-13	105,1
98	Feb-13	107,64
99	Mar-13	102,52
100	Apr-13	98,85
101	Mei-13	99,37
102	Jun-13	99,74
103	Jul-13	105,26
104	Agu-13	108,16
105	Sep-13	108,76
106	Okt-13	105,43
107	Nov-13	102,63
108	Des-13	105,48
109	Jan-14	102,1

No.	Waktu	Harga Minyak (US\$/Barrel)
110	Feb-14	104,83
111	Mar-14	104,04
112	Apr-14	104,87
113	Mei-14	105,71
114	Jun-14	108,37
115	Jul-14	105,23
116	Agu-14	100,05
117	Sep-14	95,85
118	Okt-14	86,08
119	Nov-14	76,99
120	Des-14	60,7
121	Jan-15	47,11
122	Feb-15	54,79
123	Mar-15	52,83
124	Apr-15	57,54
125	Mei-15	62,51
126	Jun-15	61,31
127	Jul-15	54,34
128	Agu-15	45,69
129	Sep-15	46,28
130	Okt-15	46,96
131	Nov-15	43,11
132	Des-15	36,57
133	Jan-16	29,78
134	Feb-16	31,03
135	Mar-16	37,34
136	Apr-16	40,75
137	Mei-16	45,94
138	Jun-16	47,69
139	Jul-16	44,13
140	Agu-16	44,88
141	Sep-16	45,04
142	Okt-16	49,29
143	Nov-16	45,26
144	Des-16	52,62
145	Jan-17	53,59
146	Feb-17	54,35

No.	Waktu	Harga Minyak (US\$/Barrel)
147	Mar-17	50,9
148	Apr-17	52,16
149	Mei-17	49,89
150	Jun-17	46,17
151	Jul-17	47,66
152	Agu-17	49,94
153	Sep-17	52,95
154	Okt-17	54,92
155	Nov-17	59,93
156	Des-17	61,19
157	Jan-18	66,23
158	Feb-18	63,46

**Lampiran 2 : Data Training**

No.	X1	X2	Target
1	44,82	42,97	50,94
2	50,94	44,82	50,64
3	50,64	50,94	47,83
4	47,83	50,64	53,89
5	53,89	47,83	56,37
6	56,37	53,89	61,89
7	61,89	56,37	61,69
8	61,69	61,89	58,19
9	58,19	61,69	55,04
10	55,04	58,19	56,43
11	56,43	55,04	62,46
12	62,46	56,43	59,7
13	59,7	62,46	60,93
14	60,93	59,7	67,97
15	67,97	60,93	68,68
16	68,68	67,97	68,29
17	68,29	68,68	72,45
18	72,45	68,29	71,81
19	71,81	72,45	62,12
20	62,12	71,81	57,91
21	57,91	62,12	58,14
22	58,14	57,91	60,99
23	60,99	58,14	53,52
24	53,52	60,99	57,56
25	57,56	53,52	60,6
26	60,6	57,56	65,06
27	65,06	60,6	65,16
28	65,16	65,06	68,19
29	68,19	65,16	73,6
30	73,6	68,19	70,13
31	70,13	73,6	76,76
32	76,76	70,13	81,97
33	81,97	76,76	91,34
34	91,34	81,97	89,52
35	89,52	91,34	90,69
36	90,69	89,52	93,39

No.	X1	X2	Target
37	93,39	90,69	101,84
38	101,84	93,39	108,76
39	108,76	101,84	122,63
40	122,63	108,76	131,52
41	131,52	122,63	132,83
42	132,83	131,52	114,57
43	114,57	132,83	99,66
44	99,66	114,57	72,69
45	72,69	99,66	53,97
46	53,97	72,69	41,34
47	41,34	53,97	43,86
48	43,86	41,34	41,84
49	41,84	43,86	46,65
50	46,65	41,84	50,28
51	50,28	46,65	58,15
52	58,15	50,28	69,15
53	69,15	58,15	64,67
54	64,67	69,15	71,63
55	71,63	64,67	68,35
56	68,35	71,63	74,08
57	74,08	68,35	77,55
58	77,55	74,08	74,88
59	74,88	77,55	77,12
60	77,12	74,88	74,76
61	74,76	77,12	79,3
62	79,3	74,76	84,18
63	84,18	79,3	75,62
64	75,62	84,18	74,73
65	74,73	75,62	74,58
66	74,58	74,73	75,83
67	75,83	74,58	76,12
68	76,12	75,83	81,72
69	81,72	76,12	84,53
70	84,53	81,72	90,01
71	90,01	84,53	92,69
72	92,69	90,01	97,91

No.	X1	X2	Target
73	97,91	92,69	108,65
74	108,65	97,91	116,24
75	116,24	108,65	108,07
76	108,07	116,24	105,85
77	105,85	108,07	107,92
78	107,92	105,85	100,49
79	100,49	107,92	100,82
80	100,82	100,49	99,85
81	99,85	100,82	105,41
82	105,41	99,85	104,23
83	104,23	105,41	107,07
84	107,07	104,23	112,69
85	112,69	107,07	117,79
86	117,79	112,69	113,67
87	113,67	117,79	104,09
88	104,09	113,67	90,73
89	90,73	104,09	96,75
90	96,75	90,73	105,27
91	105,27	96,75	106,28
92	106,28	105,27	103,41
93	103,41	106,28	101,17
94	101,17	103,41	101,19

No.	X1	X2	Target
95	101,19	101,17	105,1
96	105,1	101,19	107,64
97	107,64	105,1	102,52
98	102,52	107,64	98,85
99	98,85	102,52	99,37
100	99,37	98,85	99,74
101	99,74	99,37	105,26
102	105,26	99,74	108,16
103	108,16	105,26	108,76
104	108,76	108,16	105,43
105	105,43	108,76	102,63
106	102,63	105,43	105,48
107	105,48	102,63	102,1
108	102,1	105,48	104,83
109	104,83	102,1	104,04
110	104,04	104,83	104,87
111	104,87	104,04	105,71
112	105,71	104,87	108,37
113	108,37	105,71	105,23
114	105,23	108,37	100,05
115	100,05	105,23	95,85
116	95,85	100,05	86,08
117	86,08	95,85	76,99



**Lampiran 3 : Data Testing**

No.	X1	X2	Target
1	76,99	86,08	60,7
2	60,7	76,99	47,11
3	47,11	60,7	54,79
4	54,79	47,11	52,83
5	52,83	54,79	57,54
6	57,54	52,83	62,51
7	62,51	57,54	61,31
8	61,31	62,51	54,34
9	54,34	61,31	45,69
10	45,69	54,34	46,28
11	46,28	45,69	46,96
12	46,96	46,28	43,11
13	43,11	46,96	36,57
14	36,57	43,11	29,78
15	29,78	36,57	31,03
16	31,03	29,78	37,34
17	37,34	31,03	40,75
18	40,75	37,34	45,94
19	45,94	40,75	47,69

No.	X1	X2	Target
20	47,69	45,94	44,13
21	44,13	47,69	44,88
22	44,88	44,13	45,04
23	45,04	44,88	49,29
24	49,29	45,04	45,26
25	45,26	49,29	52,62
26	52,62	45,26	53,59
27	53,59	52,62	54,35
28	54,35	53,59	50,9
29	50,9	54,35	52,16
30	52,16	50,9	49,89
31	49,89	52,16	46,17
32	46,17	49,89	47,66
33	47,66	46,17	49,94
34	49,94	47,66	52,95
35	52,95	49,94	54,92
36	54,92	52,95	59,93
37	59,93	54,92	61,19
38	61,19	59,93	66,23
39	66,23	61,19	63,46

**Lampiran 4 : Bobot Jaringan GRNN**

No.	V <sub>11</sub>	V <sub>12</sub>	W <sub>11</sub>
1	0.1459	0.1280	0.2053
2	0.2053	0.1459	0.2024
3	0.2024	0.2053	0.1752
4	0.1752	0.2024	0.2340
5	0.2340	0.1752	0.2580
6	0.2580	0.2340	0.3116
7	0.3116	0.2580	0.3097
8	0.3097	0.3116	0.2757
9	0.2757	0.3097	0.2451
10	0.2451	0.2757	0.2586
11	0.2586	0.2451	0.3171
12	0.3171	0.2586	0.2903
13	0.2903	0.3171	0.3023
14	0.3023	0.2903	0.3706
15	0.3706	0.3023	0.3775
16	0.3775	0.3706	0.3737
17	0.3737	0.3775	0.4141
18	0.4141	0.3737	0.4079
19	0.4079	0.4141	0.3138
20	0.3138	0.4079	0.2730
21	0.2730	0.3138	0.2752
22	0.2752	0.2730	0.3029
23	0.3029	0.2752	0.2304
24	0.2304	0.3029	0.2696
25	0.2696	0.2304	0.2991
26	0.2991	0.2696	0.3424
27	0.3424	0.2991	0.3433
28	0.3433	0.3424	0.3727
29	0.3727	0.3433	0.4252
30	0.4252	0.3727	0.3916
31	0.3916	0.4252	0.4559
32	0.4559	0.3916	0.5065
33	0.5065	0.4559	0.5974
34	0.5974	0.5065	0.5797
35	0.5797	0.5974	0.5911
36	0.5911	0.5797	0.6173
37	0.6173	0.5911	0.6993
38	0.6993	0.6173	0.7664

No.	V <sub>11</sub>	V <sub>12</sub>	W <sub>11</sub>
39	0.7664	0.6993	0.9010
40	0.9010	0.7664	0.9873
41	0.9873	0.9010	1.0000
42	1.0000	0.9873	0.8228
43	0.8228	1.0000	0.6781
44	0.6781	0.8228	0.4164
45	0.4164	0.6781	0.2347
46	0.2347	0.4164	0.1122
47	0.1122	0.2347	0.1366
48	0.1366	0.1122	0.1170
49	0.1170	0.1366	0.1637
50	0.1637	0.1170	0.1989
51	0.1989	0.1637	0.2753
52	0.2753	0.1989	0.3820
53	0.3820	0.2753	0.3386
54	0.3386	0.3820	0.4061
55	0.4061	0.3386	0.3743
56	0.3743	0.4061	0.4299
57	0.4299	0.3743	0.4636
58	0.4636	0.4299	0.4377
59	0.4377	0.4636	0.4594
60	0.4594	0.4377	0.4365
61	0.4365	0.4594	0.4805
62	0.4805	0.4365	0.5279
63	0.5279	0.4805	0.4448
64	0.4448	0.5279	0.4362
65	0.4362	0.4448	0.4347
66	0.4347	0.4362	0.4469
67	0.4469	0.4347	0.4497
68	0.4497	0.4469	0.5040
69	0.5040	0.4497	0.5313
70	0.5313	0.5040	0.5845
71	0.5845	0.5313	0.6105
72	0.6105	0.5845	0.6611
73	0.6611	0.6105	0.7654
74	0.7654	0.6611	0.8390
75	0.8390	0.7654	0.7597
76	0.7597	0.8390	0.7382

No.	V <sub>11</sub>	V <sub>12</sub>	W <sub>11</sub>
77	0.7382	0.7597	0.7583
78	0.7583	0.7382	0.6862
79	0.6862	0.7583	0.6894
80	0.6894	0.6862	0.6800
81	0.6800	0.6894	0.7339
82	0.7339	0.6800	0.7225
83	0.7225	0.7339	0.7500
84	0.7500	0.7225	0.8046
85	0.8046	0.7500	0.8541
86	0.8541	0.8046	0.8141
87	0.8141	0.8541	0.7211
88	0.7211	0.8141	0.5915
89	0.5915	0.7211	0.6499
90	0.6499	0.5915	0.7326
91	0.7326	0.6499	0.7424
92	0.7424	0.7326	0.7145
93	0.7145	0.7424	0.6928
94	0.6928	0.7145	0.6930
95	0.6930	0.6928	0.7309
96	0.7309	0.6930	0.7556

115	0.6819	0.7322	0.6411
116	0.6411	0.6819	0.5463
117	0.5463	0.6411	0.4581

No.	V <sub>11</sub>	V <sub>12</sub>	W <sub>11</sub>
97	0.7556	0.7309	0.7059
98	0.7059	0.7556	0.6703
99	0.6703	0.7059	0.6753
100	0.6753	0.6703	0.6789
101	0.6789	0.6753	0.7325
102	0.7325	0.6789	0.7606
103	0.7606	0.7325	0.7664
104	0.7664	0.7606	0.7341
105	0.7341	0.7664	0.7069
106	0.7069	0.7341	0.7346
107	0.7346	0.7069	0.7018
108	0.7018	0.7346	0.7283
109	0.7283	0.7018	0.7206
110	0.7206	0.7283	0.7287
111	0.7287	0.7206	0.7368
112	0.7368	0.7287	0.7626
113	0.7626	0.7368	0.7322
114	0.7322	0.7626	0.6819

## Lampiran 5 : Pelatihan Jaringan FFNN Pemrograman Matlab

**Neural Network**

**Algorithms**

Data Division: Random (dividerand)  
Training: Levenberg-Marquardt (trainlm)  
Performance: Mean Squared Error (mse)  
Calculations: MEX

**Progress**

Epoch:	0	13 iterations	100
Time:		0:01:02	
Performance:	0.550	0.00318	0.00
Gradient:	1.05	0.00369	1.00e-07
Mu:	0.00100	1.00e-05	1.00e+10
Validation Checks:	0	6	6

**Plots**

Performance (plotperform)  
 Training State (plottrainstate)  
 Regression (plotregression)

Plot Interval:  epochs

Validation stop.

## Lampiran 6 : Source Code GRNN

```
%input data
data=xlsread('skripsi1.xlsx');
%normalisasi data pelatihan
x1=data(1:117,1)';
minVal = min(x1);
maxVal = max(x1);
xn1 = (x1 - minVal) / ( maxVal - minVal );
x2=data(1:117,2)';
minVal = min(x2);
maxVal = max(x2);
xn2 = (x2 - minVal) / ( maxVal - minVal );
xn = [xn1 xn2];
xn1= xn1';
xn2 = xn2';
xn = [xn1 xn2];
xn = xn';
y = data(1:117,3)';
minVal = min(y);
maxVal = max(y);
yn = (y - minVal) / ( maxVal - minVal );
%pembentukan jaringan GRNN
net=newgrnn(xn,yn,0.03);
hasil=sim(net,xn);
%denormalisasi data pelatihan
```

```

hasil_aktual = minVal + hasil.*(maxVal - minVal);

%MSE dan MAPE

e1=yn-hasil;

mse1=mse(e1);

mape=[abs((yn-hasil)./yn).*100];

MAPE=sum(mape)/118;

%plot pelatihan

n=length(hasil);

plot(1:n,hasil,1:n,yn);grid;

legend('GRNN Harga Minyak WTI','Real data Harga Minyak WTI');

title('Pelatihan GRNN');

%normalisasi data pengujian

xuji1 = data(118:156,1);
minVal = min(xuji1);
maxVal = max(xuji1);
xujin1 = (xuji1 - minVal) / ( maxVal - minVal );
xuji2 = data(118:156,2);
minVal = min(xuji2);
maxVal = max(xuji2);
xujin2 = (xuji2 - minVal) / ( maxVal - minVal );
xujin2 = (xuji2 - minVal) / ( maxVal - minVal );
xujin2 = (xuji2 - minVal) / ( maxVal - minVal );
xujin = [xujin1 xujin2];
xujin = xujin';

targetuji = data(118:156,3);
minVal = min(targetuji);
maxVal = max(targetuji);
targetujin = (targetuji - minVal) / ( maxVal - minVal );
targetujin = targetujin';

```

```

%hasil jaringan GRNN data pengujian
hasil1=sim(net,xujin);

%denormalisasi data pelatihan
hasil_aktual1 = minVal + hasil1.*(maxVal - minVal);

%MSE dan MAPE
e2=targetujin-hasil1;
mse2=mse(e2);
mape2=[abs(((targetujin-hasil1)./targetujin).*100)];

MAPE2=sum(mape)/39;

%plot pengujian
n=length(hasil1);

plot(1:n,hasil1,1:n,targetujin);grid;

legend('GRNN Harga Minyak WTI','Real data Harga Minyak WTI');

title('Pengujian GRNN');

%Peramalan
data=xlsread('skripsi1.xlsx');
masukan1=data(1:117,1);
minVal = min(masukan1);
maxVal = max(masukan1);
xn1 = (masukan1 - minVal) / ( maxVal - minVal );
masukan2=data(1:117,2);
minVal = min(masukan2);
maxVal = max(masukan2);
xn2 = (masukan2 - minVal) / ( maxVal - minVal );
xn = [ xn1 xn2];
xn = xn';

target=data(1:117,3);
minVal = min(target);
maxVal = max(target);
yn = (target - minVal) / ( maxVal - minVal );

```

```

yn = yn';
net=newgrnn(xn,yn,0.03);
y=sim(net,xn);
Maret = data (155:156,6);
Hasil_Maret = sim (net, Maret);
April = data (156:157,6);
Hasil_April = sim (net, April);
Mei = data (157:158,6);
Hasil_Mei = sim (net, Mei);
Juni = data (158:159,6);
Hasil_Juni = sim (net, Juni);
Juli = data (159:160,6);
Hasil_Juli = sim (net, Juli);
Agustus = data (160:159,6);
Hasil_Agustus = sim (net, Agustus);
%denormalisasi hasil peramalan
hasil_aktual_Maret = minVal + hasil_Maret.*(maxVal - minVal);
hasil_aktual_April = minVal + hasil_April.*(maxVal - minVal);
hasil_aktual_Mei = minVal + hasil_Mei.*(maxVal - minVal);
hasil_aktual_Juni = minVal + hasil_Juni.*(maxVal - minVal);
hasil_aktual_Juli = minVal + hasil_Juli.*(maxVal - minVal);
hasil_aktual_Agustus = minVal + hasil_Agustus.*(maxVal - minVal);

```



## Lampiran 7 : Source Code FFNN

```
%input data
data=xlsread('skripsi1.xlsx');

%normalisasi data pelatihan

x1=data(1:117,1)';

minVal = min(x1);

maxVal = max(x1);

xn1 = (x1 - minVal) / ( maxVal - minVal );

x2=data(1:117,2)';

minVal = min(x2);

maxVal = max(x2);

xn2 = (x2 - minVal) / ( maxVal - minVal );

xn = [xn1 xn2];

xn1= xn1';

xn2 = xn2';

xn = [xn1 xn2];

xn = xn';

y = data(1:117,3)';

minVal = min(y);

maxVal = max(y);

yn = (y - minVal) / ( maxVal - minVal );

%pembentukan jaringan FFNN
net=newff(xn, yn, [2 1],{'logsig','logsig','purelin'});
hasil=sim(net,xn);
BobotAwal_input=net.IW{1,1};
BobotAwal_bias=net.b{1,1};
BobotAwal_lapisan1=net.LW{2,1};
BobotAwal_bias_lapisan1=net.b{2,1};
```

```

net.trainParam.epochs=100;
net.trainParam.lr=0.01;
net.trainParam.mc=0.9;
net = train(net,xn,yn);
BobotAkhir_input=net.IW{1,1};
BobotAkhir_bias=net.b{1,1};
BobotAkhir_lapisan1=net.LW{2,1};
BobotAkhir_bias_lapisan1=net.b{2,1};
hasil = net(xn);

%denormalisasi data pelatihan

hasil_aktual = minVal + hasil.*(maxVal - minVal);

%MSE dan MAPE

e1=yn-hasil;

mse1=mse(e1);

mape=[abs((yn-hasil)./yn).*100];

MAPE=sum(mape)/118;

%plot pelatihan

n=length(hasil);

plot(1:n,hasil,1:n,yn);grid;

legend('FFNN Harga Minyak WTI','Real data Harga Minyak WTI');

title('Pelatihan FFNN');

%normalisasi data pengujian

xuji1 = data(118:156,1);
minVal = min(xuji1);
maxVal = max(xuji1);
xujin1 = (xuji1 - minVal) / ( maxVal - minVal );
xuji2 = data(118:156,2);
minVal = min(xuji2);
maxVal = max(xuji2);
xujin2 = (xuji2 - minVal) / ( maxVal - minVal );

```

```

xujin2 = (xuji2 - minVal) / ( maxVal - minVal );
xujin2 = (xuji2 - minVal) / ( maxVal - minVal );
xujin = [xujin1 xujin2];
xujin = xujin';
targetuji = data(118:156,3);
minVal = min(targetuji);
maxVal = max(targetuji);
targetujin = (targetuji - minVal) / ( maxVal - minVal );
targetujin = targetujin';
%hasil jaringan FFNN data pengujian
hasil1=net(xujin);
%denormalisasi data pelatihan
hasil_aktual1 = minVal + hasil1.*(maxVal - minVal);
%MSE dan MAPE
e2=targetujin-hasil1;
mse2=mse(e2);
mape2=[abs((targetujin-hasil1)./targetujin).*100)];
MAPE2=sum(mape)/39;
%plot pelatihan
n=length(hasil1);
plot(1:n,hasil1,1:n,targetujin);grid;
legend('FFNN Harga Minyak WTI','Real data Harga Minyak WTI');
title('Pengujian FFNN);
%Peramalan
data=xlsread('skripsi1.xlsx');
masukan1=data(1:117,1);
minVal = min(masukan1);
maxVal = max(masukan1);
xn1 = (masukan1 - minVal) / ( maxVal - minVal );
masukan2=data(1:117,2);
minVal = min(masukan2);

```

```

maxVal = max(masukan2);
xn2 = (masukan2 - minVal) / ( maxVal - minVal );
xn = [ xn1 xn2];
xn = xn';
target=data(1:117,3);
minVal = min(target);
maxVal = max(target);
yn = (target - minVal) / ( maxVal - minVal );
yn = yn';
net=newff(xn, yn, [2 1],{'logsig','logsig','purelin'});
net.trainParam.epochs=100;
net.trainParam.lr=0.01;
net.trainParam.mc=0.9;
BobotAkhir_input=net.IW{1,1};
BobotAkhir_bias=net.b{1,1};
BobotAkhir_lapisan1=net.LW{2,1};
BobotAkhir_bias_lapisan1=net.b{2,1};
net = train(net,xn,yn);
y=net(xn);
Maret = data (155:156,6);
Hasil_Maret = net (Maret);
April = data (156:157,6);
Hasil_ April = net (April);
Mei = data (157:158,6);
Hasil_ Mei = net (Mei);
Juni = data (158:159,6);
Hasil_ Juni = net (Juni);
Juli = data (160:161,6);
Hasil_ Juli = net (Juli);
Agustus = data (162:163,6);
Hasil_ Agustus = net (Agustus);

%denormalisasi hasil peramalan
hasil_aktual_Maret = minVal + hasil_Maret.*(maxVal - minVal);

```

```
hasil_aktual_April = minVal + hasil_April.*(maxVal - minVal);  
hasil_aktual_Mei = minVal + hasil_Mei.*(maxVal - minVal);  
hasil_aktual_Juni = minVal + hasil_Juni.*(maxVal - minVal);  
hasil_aktual_Juli = minVal + hasil_Juli.*(maxVal - minVal);  
hasil_aktual_Agustus = minVal + hasil_Agustus.*(maxVal - minVal);
```