

**PENERAPAN *ARTIFICIAL NEURAL NETWORK* ALGORITMA
BACKPROPAGATION DALAM MEMPREDIKSI HARGA EMAS**

Skripsi

Oleh

**DWI OKTAVIA
NPM 1717031015**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

**PENERAPAN *ARTIFICIAL NEURAL NETWORK* ALGORITMA
BACKPROPAGATION DALAM MEMPREDIKSI HARGA EMAS**

Oleh

Dwi Oktavia

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

ABSTRAK

PENERAPAN *ARTIFICIAL NEURAL NETWORK* ALGORITMA *BACKPROPAGATION* DALAM MEMPREDIKSI HARGA EMAS

Oleh

DWI OKTAVIA

Time Series adalah pengamatan pada suatu variabel dari waktu lampau dan dicatat secara berurutan menurut urutan waktu dengan periode yang tetap. Data dari waktu lampau harga emas merupakan salah satu data *time series*. Pada umumnya orang memilih berinvestasi dalam bentuk emas untuk memperoleh keuntungan. Tujuan dari penelitian ini adalah menjelaskan prosedur pembentukan model *Feedforward Neural Network* (FFNN) dengan Algoritma *Backpropagation* (BP) dan meramalkan harga emas menggunakan model tersebut.

Proses pembentukan model *Feedforward neural network* dengan algoritma *Backpropagation* pada data *time series* terdiri atas beberapa tahap, yaitu (1) menentukan input berdasarkan plot ACF dan PACF, (2) melakukan pembagian data menjadi 2 yaitu data *training* dan data *testing*, (3) menormalisasi data, (4) membangun model *Feedforward neural network* dengan algoritma *Backpropagation*, yaitu menentukan jumlah *neuron* pada lapis tersembunyi dan menentukan bobot model, (5) denormalisasi dan (6) uji kesesuaian model. Langkah tersebut menghasilkan model yang terbaik, yang dapat digunakan untuk peramalan.

Model FFNN dengan algoritma BP ini diterapkan pada data harga emas bulan Februari 2013 sampai Februari 2021 dengan variabel inputnya yaitu harga emas dunia. Struktur jaringan terbaik yang diperoleh adalah dengan 3 *neuron input*, 5 *neuron* pada *hidden layer* 1, dan 4 *neuron* pada *hidden layer* 2 dengan menggunakan fungsi aktivasi Tanh. Hasil peramalan harga emas untuk 10 periode ke depan menghasilkan error terkecil pada 9 Februari 2021 yaitu sebesar 1.491, dan error terbesar pada tanggal 5 Februari 2021 sebesar 47.518 dengan menghasilkan MAPE sebesar 0.74%.

Kata kunci : *Feedforward Neural Network*, *Backpropagation*, peramalan, harga emas

ABSTRACT

APPLICATION OF ARTIFICIAL NEURAL NETWORK BACKPROPAGATION ALGORITHM IN PREDICTING GOLD PRICE

By

DWI OKTAVIA

Time Series is an observation on a variable from the past and recorded sequentially according to the time sequence with a fixed period. In general, people choose to invest in gold to make a profit. The purpose of this study is to explain the procedure for establishing a Feedforward Neural Network (FFNN) model with the Backpropagation Algorithm (BP) and predicting the price of gold using this model.

The process of forming a Feedforward neural network model with the Backpropagation algorithm on time series data consists of several stages, namely (1) determining the input based on the ACF and PACF plots, (2) dividing the data into 2, namely training data and testing data, (3) normalizing the data, (4) build a Feedforward neural network model with the Backpropagation algorithm, which determines the number of neurons in the hidden layer and determines the weight of the model, (5) denormalization and (6) model suitability test. This step produces the best model, which can be used for forecasting.

The FFNN model with the BP algorithm is applied to gold price data from February 2013 to February 2021 with the input variable, namely the world gold price. The best network structure obtained is with 3 input neurons, 5 neurons in hidden layer 1, and 4 neurons in hidden layer 2 using the Tanh activation function. The results of forecasting gold prices for the next 10 periods produced the smallest error on February 9, 2021, which was 1.491, and the largest error on February 5, 2021, amounted to 47.518 by producing a MAPE of 0.74%.

Keywords: Feedforward Neural Network, Backpropagation, forecasting, gold price

Judul Skripsi : **PENERAPAN ARTIFICIAL NEURAL
NETWORK ALGORITMA
BACKPROPAGATION DALAM
MEMPREDIKSI HARGA EMAS**

Nama Mahasiswa : **Dwi Oktavia**

Nomor Pokok Mahasiswa : 1717031015

Program Studi : Matematika

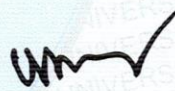
Fakultas : Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing

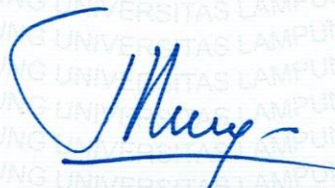


Dian Kurniasari, S.Si., M.Sc.
NIP 19690305 199603 2 001



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

2. Ketua Jurusan Matematika



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

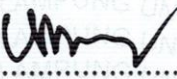
MENGESAHKAN

1. Tim Penguji

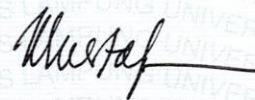
Ketua : **Dian Kurniasari, S.Si., M.Sc.**



Sekretaris : **Ir. Warsono, M.S., Ph.D.**



Anggota : **Prof. Drs. Mustofa Usman, M.A., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Suropto Dwi Yuwono, M.T.
NIP. 19740705 200003 1 001

Tanggal Lulus Ujian Skripsi : **5 Agustus 2021**

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan dibawah ini:

Nama : **Dwi Oktavia**

Nomor Pokok Mahasiswa : **1717031015**

Jurusan : **Matematika**

Judul : **Penerapan *Artificial Neural Network* Algoritma *Backpropagation* dalam Memprediksi Harga Emas**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri, bukan hasil orang lain, dan semua hasil tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil Salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, Agustus 2021

Penulis,



Dwi Oktavia

RIWAYAT HIDUP

Penulis bernama lengkap Dwi Oktavia, dilahirkan di Purwoadi, Lampung Tengah pada tanggal 15 Oktober 1999, sebagai anak bungsu dari dua bersaudara, dari Bapak Pawitno dan Ibu Ramisem.

Penulis menempuh pendidikan dasar di SD Negeri 1 Purwoadi pada tahun 2005-2011, lalu melanjutkan pendidikan di SMP Negeri 1 Trimurjo dan lulus pada tahun 2014. Kemudian menempuh pendidikan di SMA Negeri 1 Trimurjo hingga lulus pada tahun 2017.

Pada tahun 2017, penulis diterima sebagai mahasiswa di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nilai Masuk Perguruan Tinggi Negeri (SNMPTN). Selama menjadi mahasiswa penulis aktif di Organisasi Himpunan Mahasiswa Matematika (HIMATIKA) FMIPA Unila. Pada tahun 2020, sebagai bentuk aplikasi bidang ilmu kepada masyarakat, penulis telah menyelesaikan Kerja Praktik di Badan Pengelolaan Pajak dan Retribusi Daerah (BPPRD) Kota Metro selama 40 hari, dan melaksanakan Kuliah Kerja Nyata di Desa Agung Jaya, Kecamatan Abung Jaya, Kabupaten Tulang Bawang selama 40 hari.

PERSEMBAHAN

Alhamdulillah Rabbil' Alamin...

Segala puji bagi Rabb yang tidak pernah mengecewakan hamba yang berharap kepada-Nya, dan sholawat serta salam semoga dan selalu terlisankan untuk

Rasulullaah Sholallaahu 'alayhi Wasallam

Penulis persembahkan karya ini untuk:

Ayahanda Pawitno dan Ibunda Ramisem

Terima kasih atas limpahan kasih sayang, pengorbanan, doa, dan seluruh motivasi di setiap langkahku. Karena atas doa dan ridho kalian, Allah memudahkan setiap perjalanan hidup ini. Terimalah bukti kecil ini sebagai kado keseriusanku untuk membalas semua pengorbanan, keikhlasan, dan jerih payah yang selama ini kalian lakukan.

Kakakku Anita Sari

Terima kasih atas dukungan, kebaikan, perhatian dan kebijaksanaan yang telah engkau berikan.

Almamaterku Tercinta Universitas Lampung

Kata Inspirasi

“Lakukan kebaikan sekecil apapun, karena engkau tidak pernah tau kebaikan mana yang akan membawamu ke surga”

(Imam Al-Hasan)

“Setiap pria dan wanita sukses adalah pemimpi-pemimpi besar. Mereka berimajinasi tentang masa depan mereka, berbuat sebaik mungkin dalam setiap hal, dan bekerja setiap hari menuju visi jauh ke depan yang menjadi tujuan mereka “

(Brian Tracy)

"Sesungguhnya sesudah kesulitan itu ada kemudahan, sesungguhnya sesudah kesulitan itu ada kemudahan."

(Asy-Syarh ayat 5-6)

“Hidup adalah sebuah petualangan”

(Dwi Oktavia)

UCAPAN TERIMA KASIH

Puji syukur penulis ucapkan kehadiran Tuhan Yang Maha Esa, karena atas rahmat dan hidayah-Nya sehingga dapat terselesaikan skripsi dengan judul “*Penerapan Artificial Neural Network Algoritma Backpropagation Dalam Memprediksi Harga Emas*” sebagai salah satu syarat untuk memperoleh gelar sarjana Matematika di Universitas Lampung.

Dalam kesempatan ini penulis mengucapkan terima kasih kepada:

1. Ibu Dian Kurniasari, S.Si., M.Sc., selaku pembimbing utama atas kesediaannya untuk memberikan bimbingan, saran dan kritik dalam proses penyelesaian skripsi ini;
2. Bapak Ir. Warsono, M.S., Ph.D., selaku pembimbing kedua serta pembimbing akademik atas kesediaannya untuk memberikan bimbingan, saran dan kritik dalam proses penyelesaian skripsi ini;
3. Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D., selaku penguji utama pada ujian skripsi. Terima kasih atas masukan dan saran-saran pada seminar terdahulu;
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam;
5. Bapak Dr. Eng. Suropto Dwi Yuwono, M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam;
6. Seluruh Dosen, Staf dan Karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Bapak Pawitno, Ibu Ramisem dan keluarga yang selalu mendampingi langkah penulis dengan do'a dan nasihat untuk selalu berjuang setiap harinya
8. Anita Sari yang selalu memberi semangat, motivasi, dan do'a serta tak pernah bosan mendengar keluh kesah penulis.

9. Teman-teman Matematika 2017, Abang dan Yunda yang selalu memberikan semangat, ide dan saran kepada penulis.
10. Sahabat-sahabat Srikandi Fifi, Rosita, Siti dan teman-teman kelas A yang telah menjadi pelangi indah di masa kuliah penulis.
11. Jepri Andika yang selalu memberi semangat dan arahan dalam menyelesaikan skripsi ini.
12. Teman-teman KKN 2020 Desa Agung Jaya.
13. Semua pihak yang terlibat dalam penyelesaian skripsi ini.

Tentunya, Penulis menyadari bahwa masih ada kekurangan dari skripsi ini, akan tetapi besar harapan semoga skripsi ini dapat bermanfaat bagi kita semua. Sekian dan terima kasih.

Bandar Lampung, Agustus 2021

Dwi Oktavia

DAFTAR ISI

Halaman

DAFTAR TABEL	xv
DAFTAR GAMBAR	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tujuan Penelitian	3
1.3 Manfaat Penelitian	3
II. TINJAUAN PUSTAKA	4
2.1 Peramalan (<i>Forecasting</i>)	4
2.2 Konsep Dasar <i>Time Series</i>	5
2.2.1 Autokorelasi	5
2.2.2 Proses <i>White Noise</i>	8
2.2.3 Pola Data <i>Time Series</i>	8
2.3 <i>Statistical Learning</i>	10
2.4 <i>Artificial Neural Network</i>	11
2.4.1 Arsitektur <i>Artificial Neural Network</i>	13
2.4.2 Fungsi Aktivasi	15
2.4.3 <i>Backpropagation</i> pada <i>Artificial Neural Network</i>	19
2.5 Investasi Emas	21
2.6 Akurasi Model	23
III. METODOLOGI PENELITIAN	25
3.1 Waktu dan Tempat Penelitian	25
3.2 Spesifikasi Komputer	25
3.3 Data Penelitian	25
3.4 Metode Penelitian	26
IV. HASIL DAN PEMBAHASAN	30
4.1 Membangun Jaringan <i>Feedforward neural network</i> dengan algoritma <i>Backpropagation</i>	30
4.1.1 Menentukan Input	30
4.1.2 Pembagian Data	30
4.1.3 <i>Pre-processing</i> Data	31
4.1.4 Menentukan Model FFNN yang optimal dengan Algoritma <i>Backpropagation</i>	32
4.1.5 Denormalisasi	34
4.1.6 Uji Kesesuaian Model	35

4.2 Penerapan model <i>Feedforward Neural Network</i> algoritma <i>Backpropagation</i> untuk melakukan peramalan harga emas	35
4.2.1 Membangun jaringan <i>feedforward neural network</i> dengan algoritma <i>backpropagation</i> untuk peramalan harga emas	35
4.2.1.1 Penentuan input jaringan	35
4.2.1.2 Pembagian data	37
4.2.1.3 <i>Pre-processing</i> Data	37
4.2.1.4 Menentukan model FFNN yang optimal dengan Algoritma <i>Backpropagation</i>	38
4.2.1.5 Denormalisasi	42
4.2.1.6 Uji Kesesuaian Model	43
4.2.1.7 Akurasi Model.....	46
4.2.2 Peramalan harga Emas	46
V. KESIMPULAN	50
DAFTAR PUSTAKA	51
LAMPIRAN	54

DAFTAR TABEL

Tabel	Halaman
1. Simbol-simbol Algoritma <i>Backpropagation</i>	28
2. <i>Multilayer Perceptron</i> dengan Satu <i>Hidden Layer</i>	39
3. <i>Multilayer Perceptron</i> dengan Dua <i>Hidden Layer</i>	39
4. Hasil Peramalan Harga Emas Dunia 2-14 Februari 2021	48
5. Harga Emas Indonesia periode 2–14 Februari 2021	49

DAFTAR GAMBAR

Gambar	Halaman
1. Plot autokorelasi pada data <i>time series</i>	7
2. Pola Data Horisontal	9
3. Pola Data Musiman	9
4. Pola Data Siklis	9
5. Pola Data Trend	10
6. Arsitektur jaringan <i>artificial neural network</i> sederhana	13
7. Arsitektur jaringan <i>artificial neural network single layer</i>	14
8. Arsitektur jaringan <i>artificial neural network multilayer</i>	15
9. Fungsi Aktivasi <i>Logistic</i>	16
10. Fungsi Aktivasi ReLU (<i>Rectified Linear Unit</i>)	17
11. Fungsi Aktivasi <i>Leaky ReLU</i>	17
12. Fungsi Aktivasi <i>Tanh</i>	18
13. Fungsi Aktivasi <i>ELU</i>	19
14. Arsitektur Jaringan <i>Backpropagation</i>	20
15. <i>Flowchart</i> Sistem Pelatihan dan Pengujian Algoritma <i>Backpropagation</i>	29
16. Plot ACF data harga open emas dunia	36
17. Plot PACF data harga open emas dunia.	36
18. Jaringan <i>Feedforward Neural Network</i> algoritma <i>Backpropagation</i> fungsi aktivasi <i>Tanh</i> dengan dua <i>hidden layer</i>	41
19. Plot Perbandingan antara data prediksi dengan data aktual dari proses denormalisasi	42
20. Plot ACF model FFNN algoritma <i>Backpropagation</i> dengan dua lapis tersembunyi serta x_1, x_2, x_3 sebagai input	43
21. Plot PACF model FFNN algoritma <i>Backpropagation</i> dengan dua lapis tersembunyi serta x_1, x_2, x_3 sebagai input	44
22. Arsitektur model <i>Feedforward Neural Network</i> dengan algoritma <i>Backpropagation</i> fungsi aktivasi <i>Tanh</i> pada peramalan harga open emas	45

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Emas merupakan salah satu logam mulia yang bernilai di dunia yang bersifat lunak, tahan korosi dan mudah ditempa. Para pakar investasi seringkali menganjurkan untuk berinvestasi pada emas karena emas merupakan sarana lindung nilai klasik untuk melawan inflasi dan menambah nilai dalam kondisi ketidakstabilan fluktuasi nilai mata uang (Diantoro, 2010). Investasi dalam emas dibedakan menjadi dua jenis yaitu, investasi pada saham emas dan investasi pada emas batangan.

Pertumbuhan ekonomi yang pesat di negara berkembang terutama China dan India memicu kenaikan konsumsi emas di negara tersebut sebagai lindung nilai mata uang, perhiasan, dan industri. Permintaan terhadap emas yang tidak pernah berkurang sementara emas memiliki *supply* yang terbatas menjadikan harga emas cenderung stabil dan naik (Diantoro, 2010). Harga emas yang nyaris tidak pernah turun tersebut melatarbelakangi minat beli investor terhadap emas. Faktor yang mempengaruhi kenaikan atau penurunan harga emas adalah krisis finansial, naiknya permintaan emas di pasaran, kurs dollar, dan situasi politik dunia.

Salah satu pengetahuan penting berinvestasi emas adalah peramalan harga emas. Peramalan adalah proses perkiraan (pengukuran) besarnya atau jumlah sesuatu pada waktu yang akan datang berdasarkan data masa lampau (*time series*) yang dianalisis secara ilmiah khususnya menggunakan metode statistika (Lewis, 2017). Peramalan harga emas bertujuan untuk mengetahui peluang investasi harga emas di masa yang akan datang sehingga dapat digunakan sebagai pertimbangan oleh investor emas untuk mengetahui perubahan harga emas.

Saat ini metode peramalan dalam statistika sangat banyak dan seringkali memerlukan asumsi-asumsi yang harus dipenuhi, namun terdapat model yang tidak memerlukan asumsi-asumsi, salah satunya adalah *Artificial Neural Network* (ANN). *Artificial Neural Network* adalah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf pada makhluk hidup (Fausett, 1994). Salah satu model dari *Artificial Neural Network* yaitu *Feedforward Neural Network* (FFNN), dimana proses pelatihan berjalan maju dari lapisan *input* menuju lapisan *output* selanjutnya. Algoritma *Backpropagation Neural Network* adalah model pembelajaran dari kelas FFNN yang paling banyak digunakan untuk menyelesaikan masalah data *time series*. Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur. Untuk mendapat *error* ini, tahap perambatan maju harus dikerjakan terlebih dahulu. Pada saat perambatan maju, *neuron-neuron* diaktifkan dengan menggunakan fungsi aktivasi. Fungsi aktivasi digunakan untuk menentukan keluaran suatu *neuron* (Siang, 2009).

Penggunaan FFNN untuk analisis data *time series* telah banyak dilakukan, antara lain Yuliandar dkk. (2012) menggunakan algoritma genetika dengan metode seleksi turnamen untuk data *time series*, Nurmila dkk. (2016) menggunakan algoritma *backpropagation neural network* untuk pengenalan pola karakter huruf jawa, Bambang dkk. (2004) menggunakan FFNN untuk prediksi harga saham pada pasar modal Indonesia, Pakaja dkk. (2012) menggunakan jaringan syaraf tiruan dan *certainty factor* pada peramalan penjualan mobil, Azam dkk. (2018) menggunakan FFNN dengan algoritma genetika untuk prediksi harga emas batang, Irsalinda dan Astuti (2020) mengaplikasikan model *fuzzy feedforward neural network* (FFFNN) dalam peramalan *Jakarta Islamic index* (JII), Ghufran dkk. (2018) menerapkan *particle swarm optimization* pada FFNN untuk klasifikasi teks Hadis Bukhari terjemahan Bahasa Indonesia, Kencana dkk. (2020) menggunakan metode *feedforward* dan *backpropagation neural network* untuk mendeteksi *hoaks* pada twitter. Berdasarkan uraian tersebut dalam penelitian ini penulis akan mengkaji pemodelan *Artificial Neural Network* dengan Algoritma *Backpropagation* untuk data *time series* harga emas. Penulis akan menggunakan lima macam fungsi

aktivasi dalam meramalkan harga emas dan memilih fungsi aktivasi terbaik berdasarkan tingkat akurasi model.

1.2 Tujuan Penelitian

Sesuai dengan pokok permasalahan yang telah di ambil, maka tujuan penulisan tugas akhir ini adalah:

1. Menjelaskan prosedur pembentukan model FFNN dengan algoritma *Backpropagation* pada data *time series*.
2. Meramalkan harga emas menggunakan model FFNN dengan algoritma *Backpropagation*.
3. Menentukan fungsi aktivasi terbaik untuk meramalkan harga emas berdasarkan tingkat akurasi model.

1.3 Manfaat Penelitian

Adapun manfaat yang diperoleh dari penulisan tugas akhir ini adalah:

1. Sebagai referensi atau bahan acuan untuk mengaplikasikan model FFNN dengan algoritma *Backpropagation* dalam melakukan peramalan serta sebagai bahan informasi untuk penelitian selanjutnya.
2. Bagi para investor, diharapkan penelitian ini dapat menjadi bahan pertimbangan untuk melakukan analisis investasi emas.

II. TINJAUAN PUSTAKA

2.1 Peramalan (*Forecasting*)

Peramalan adalah proses perkiraan besarnya atau jumlah sesuatu pada waktu yang akan datang berdasarkan data pada masa lampau yang di analisis secara ilmiah khususnya menggunakan metode statistika (Lewis, 2017). Peramalan biasanya dilakukan untuk mengurangi ketidakpastian terhadap sesuatu yang akan terjadi di masa yang akan datang. Suatu usaha untuk mengurangi ketidakpastian tersebut dilakukan dengan menggunakan metode peramalan.

Menurut Makridakis dkk. (1999), metode peramalan dibagi ke dalam dua kategori utama, yaitu metode kualitatif dan metode kuantitatif. Metode peramalan kualitatif dilakukan apabila data masa lalu tidak tersedia sehingga peramalan tidak bisa dilakukan. Dalam metode kualitatif, pendapat-pendapat dari para ahli akan menjadi pertimbangan dalam pengambilan keputusan sebagai hasil dari peramalan yang telah dilakukan. Namun, apabila data masa lalu tersedia, peramalan dengan metode kuantitatif akan lebih efektif digunakan dibandingkan dengan metode kualitatif. Tujuan metode kuantitatif ini adalah mempelajari apa yang telah terjadi di masa lalu untuk meramalkan nilai di waktu yang akan datang.

Peramalan dengan metode kuantitatif dapat dibagi menjadi dua bagian, yaitu (Santoso, 2009):

1. Metode peramalan yang didasarkan atas penggunaan analisa pola hubungan antara variabel yang akan diperiksa dengan variabel waktu, yang merupakan deret waktu atau *time series*.
2. Metode peramalan yang didasarkan atas penggunaan analisa pola hubungan antara variabel yang akan diperkirakan dengan variabel lain yang

mempengaruhinya, yang bukan waktu, yang disebut metode korelasi atau sebab akibat (*causal methods*).

2.2 Konsep Dasar *Time Series*

Time series adalah pengamatan pada suatu variabel dari waktu lampau dan dicatat secara berurutan menurut urutan waktu dengan periode yang tetap (Hanke dan Wichern, 2004). Pada umumnya pencatatan ini dilakukan dalam periode tertentu misalnya harian, bulanan, tahunan dan sebagainya. Sedangkan analisis *time series* adalah suatu metode kuantitatif untuk menentukan pola data masa lampau yang telah dikumpulkan secara teratur. Jika telah menemukan pola data tersebut, maka dapat digunakan untuk peramalan di masa mendatang.

2.2.1 Autokorelasi

Autokorelasi merupakan suatu korelasi pada data *time series* antara X_t dengan X_{t+k} . Untuk mendefinisikan autokorelasi diperlukan definisi autokovarians. Autokovarians dan autokorelasi antara X_t dan X_{t+k} berturut-turut dapat didefinisikan sebagai berikut (Wei, 2006):

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

dan

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

dengan:

X_t = pengamatan pada waktu ke-t

X_{t+k} = pengamatan pada waktu ke-t+k

Dimana $Var(X_t) = Var(X_{t+k}) = \gamma_0$ dan $\rho_0 = 1$. Sebagai fungsi dari k, γ_k disebut fungsi autokovarians dan ρ_k disebut sebagai fungsi autokorelasi (*autocorrelation function*) atau ACF, yang mewakili kovarians dan korelasi antara X_t dan X_{t+k} dari proses yang sama, hanya dipisahkan oleh *time lag*-k. jika X_t dan X_{t+k} independen maka $\gamma_k = Cov(X_t, X_{t+k}) = 0$ tetapi tidak berlaku sebaliknya. X_t dan X_{t+k}

dikatakan tidak berkorelasi jika $\rho_k = 0$. Dua variabel dengan hubungan negative sempurna memiliki koefisien korelasi sebesar -1. Di lain kasus, dua variabel dengan hubungan positif sempurna memiliki koefisien korelasi sebesar +1. Dengan demikian, koefisien korelasi bervariasi antara -1 dan +1 (Hanke dan Winchern, 2004).

Hipotesis untuk menguji signifikansi autokorelasi dirumuskan sebagai:

$H_0: \rho_k = 0$ (autokorelasi pada lag ke-k tidak signifikan)

$H_0: \rho_k \neq 0$ (autokorelasi pada lag ke-k signifikan)

Uji signifikan menggunakan distribusi t, dengan statistik uji:

$$t = \frac{r_k}{SE(r_k)} \quad (2.3)$$

Standar *error* dari koefisien autokorelasi menggunakan rumus sebagai berikut (Hanke dan Wichern, 2004):

$$SE(r_k) = \sqrt{\frac{1+2\sum_{i=1}^{k-1} r_i^2}{n}} \quad (2.4)$$

dengan

$SE(r_k)$ = standar *error* koefisien korelasi pada lag k


r_k = koefisien korelasi pada lag k

N = banyaknya pengamatan

Koefisien autokorelasi pada lag k dikatakan signifikan jika $t_{hitung} > t_{(n-1)}\left(\frac{\alpha}{2}\right)$ atau $t_{hitung} < -t_{(n-1)}\left(\frac{\alpha}{2}\right)$ dan apabila menggunakan nilai Sig. maka koefisien autokorelasi pada lag k dikatakan signifikan jika $\text{Sig.} < \left(\frac{\alpha}{2}\right)$. Signifikan koefisien autokorelasi juga dapat dilihat dari selang kepercayaan dengan pusat $r_k = 0$ yang apabila dilihat dari tampilan plot fungsi berupa garis putus-putus yang berwarna merah. Selang kepercayaan tersebut dicari dengan cara menghitung:

$$0 \pm t_{(n-1)}\left(\frac{\alpha}{2}\right) \times SE(r_k) \quad (2.5)$$

Pada gambar 1 menunjukkan plot autokorelasi pada deret berkala dimana garis yang keluar dari batas signifikan menunjukkan autokorelasi signifikan.



Gambar 1. Plot autokorelasi pada data *time series*.

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara X_t dan X_{t-k} , apabila pengaruh dari *time lag* 1, 2, 3, ..., dan seterusnya sampai k-1 dihilangkan. Autokorelasi parsial ditentukan dengan rumus sebagai berikut:

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \quad (2.6)$$

Dengan ϕ_{kk} adalah autokorelasi parsial antara X_t dan X_{t+k} , karena merupakan fungsi dari k, himpunan $\{\phi_{kk}; k = 0, 1, 2, \dots\}$ dinamakan fungsi autokorelasi parsial (*partial autocorrelation function*), disingkat dengan PACF (Wei, 2006).

2.2.2 Proses *White Noise*

Sebuah proses $\{e_t\}$ disebut *white noise* jika merupakan serangkaian variabel acak yang tidak berkorelasi dan berdistribusi tertentu dengan rata-rata tetap $E(e_t) = \mu$ biasanya bernilai 0, variansi konstanta $Var(e_t) = \sigma^2$ dan $Cov(e_t, e_{t+k}) = 0$ untuk semua $k \neq 0$ (Wei, 2006). Dengan demikian proses dari *white noise* $\{e_t\}$ adalah stasioner dengan fungsi autokovariansi:

$$\gamma_k = \begin{cases} \sigma_a^2 & k = 0, \\ 0 & k \neq 0, \end{cases} \quad (2.7)$$

fungsi autokorelasi

$$\rho_k = \begin{cases} 1 & k = 0, \\ 0 & k \neq 0, \end{cases} \quad (2.8)$$

dan fungsi autokorelasi parsial


$$\phi_{kk} = \begin{cases} 1 & k = 0, \\ 0 & k \neq 0, \end{cases} \quad (2.9)$$

Karena menurut definisi $\rho_0 = \phi_{00} = 1$ untuk semua proses, jika dalam autokorelasi dan autokorelasi parsial hanya mengacu pada ρ_0 dan ϕ_{kk} untuk $k \neq 0$. Konsep dasar dari proses *white noise* adalah bahwa ACF dan PACF sama dengan nol.

2.2.3 Pola Data *Time Series*


Langkah penting dalam memilih suatu metode *time series* yang tepat adalah mempertimbangkan jenis pola data, sehingga metode yang paling tepat dengan pola tersebut dapat diuji. Pola data dapat dibedakan menjadi empat jenis (Makridakis dkk., 1999), yaitu:

- a. Pola horisontal terjadi apabila nilai data berfluktuasi di sekitar nilai rata-rata yang konstan. Suatu produk yang penjualannya tidak meningkat atau menurun selama waktu tertentu termasuk jenis deret ini.




Gambar 2. Pola Data Horizontal.

- b. Pola musiman terjadi apabila suatu deret dipengaruhi oleh faktor musiman (misalnya kuartal tahun tertentu, bulanan, atau hari-hari pada minggu tertentu). Penjualan dari produk seperti minuman ringan dan es krim menunjukkan jenis pola data ini.




Gambar 3. Pola Data Musiman.

- c. Pola siklis terjadi apabila datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis. Penjualan produk mobil, baja dan peralatan utama lainnya menunjukkan pola data ini.



Gambar 4. Pola Data Siklis.

- d. Pola trend terjadi apabila terdapat kenaikan atau penurunan jangka panjang dalam data. Penjualan banyak perusahaan, produk buruto nasional (GNP) dan berbagai indikator bisnis ekonomi lainnya mengikuti suatu pola trend selama perubahannya sepanjang waktu.



Gambar 5. Pola Data Trend.

2.3 *Statistical Learning*

Statistical Learning adalah kerangka kerja yang menggambarkan pembelajaran mesin dari bidang statistik dan analisis fungsional untuk pemodelan dan pemahaman kumpulan data kompleks (James dkk., 2013). *Statistical Learning* adalah bidang yang baru-baru ini dikembangkan dalam statistik dan perkembangan ilmu komputer, khususnya *machine learning*. Bidang ini mencakup banyak metode seperti *lasso* dan *sparse regression*, *classification* dan *regression trees*, serta *boosting* dan *support vector machines*.

Statistical Learning mengacu pada seperangkat alat yang luas untuk memahami data. Alat tersebut yang dapat diklasifikasikan menjadi dua kategori, yaitu *supervised learning* dan *unsupervised learning*.

a. Pelatihan Terawasi (*Supervised Learning*)

Pelatihan ini dilakukan dengan adanya urutan vektor pelatihan, atau pola yang masing-masing terkait dengan vektor target *output*. Bobot kemudian disesuaikan untuk algoritma pembelajaran. Pada umumnya *supervised learning* melibatkan pembangunan model statistik untuk memperkirakan keluaran berdasarkan satu atau lebih masukan.

b. Pelatihan tak Terawasi (*Unsupervised Learning*)

Pada pelatihan ini jaring saraf mengatur segala kinerja dirinya sendiri, mulai dari masukan vektor hingga menggunakan data training untuk melakukan pembelajaran.

Dari perspektif teori pembelajaran statistik, *supervised learning* paling baik dipahami. *Supervised learning* melibatkan pembelajaran dari kumpulan data pelatihan. Setiap poin dalam pelatihan merupakan pasangan *input-output*, dimana *input* dipetakan ke *output*, sehingga fungsi yang dipelajari dapat digunakan untuk memprediksi *output* dari *input* yang akan datang.

Salah satu algoritma *supervised learning* yang populer adalah *artificial neural network*, yaitu sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi (Siang, 2005). Dalam pemrosesan *artificial neural network* terdapat pembagian data menjadi dua, yaitu data training dan data testing. Data training digunakan untuk melatih algoritma, sedangkan data testing dipakai untuk mengetahui performa algoritma yang sudah dilatih sebelumnya ketika menemukan data baru yang belum pernah dilihat sebelumnya. Ini biasanya disebut dengan generalisasi. Hasil dari pelatihan tersebut bisa disebut dengan model.

2.4 *Artificial Neural Network*

Artificial neural network adalah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi (Siang, 2005). *Artificial neural network* telah diaplikasikan dalam berbagai bidang diantaranya *pattern recognition*, *medical diagnostic*, *signal processing*, dan peramalan. Meskipun banyak aplikasi menjanjikan yang dapat dilakukan oleh *artificial neural network*, namun *artificial neural network* memiliki beberapa keterbatasan umum, yaitu ketidak akuratan hasil yang diperoleh. *Artificial neural network* bekerja berdasarkan pola yang terbentuk pada *inputnya*.

Artificial neural network terdiri atas elemen-elemen untuk pemrosesan informasi yang disebut dengan *neuron*, unit, sel atau *node* (Khashei, 2010). Setiap *neuron*

dihubungkan dengan *neuron* lainnya dengan suatu *connection link*, yang direpresentasikan dengan *weight*/bobot. Metode untuk menentukan nilai *weight* disebut dengan *training, learning*, atau algoritma. Setiap *neuron* menggunakan fungsi aktivasi pada net *input* untuk menentukan prediksi *output*.

Neuron-neuron dalam *artificial neural network* disusun dalam grup, yang disebut dengan *layer* (lapis). Susunan *neuron-neuron* dalam lapis dan pola koneksi di dalam dan antarlapis disebut dengan arsitektur jaringan. Arsitektur ini merupakan salah satu karakteristik penting yang membedakan *neural network*. Secara umum ada tiga lapis yang membentuk *neural network*:

1) Lapis *input*

Unit-unit di lapisan *input* disebut unit-unit *input*. Unit-unit *input* tersebut menerima pola masukan dari luar yang menggambarkan suatu permasalahan. Banyak *node* atau *neuron* dalam lapis *input* tergantung pada banyaknya *input* dalam model dan setiap *input* menentukan satu *neuron*.

2) Lapis tersembunyi (*hidden layer*)

Unit-unit dalam lapisan tersembunyi disebut unit-unit tersembunyi, dimana keluarannya tidak dapat diamati secara langsung. Lapis tersembunyi terletak di antara lapis *input* dan lapis *output*, yang dapat terdiri atas beberapa lapis tersembunyi. Menurut Huang (2003), pada kasus dua *hidden layer* dengan m *neuron output* dan N sampel, jumlah *hidden layer* pada lapis pertama dirumuskan sebagai:

$$\sqrt{(m + 2)N} + 2\sqrt{\frac{N}{m+2}}, \quad (2.10)$$

dan untuk lapis kedua dirumuskan sebagai:

$$m\sqrt{\frac{N}{m+2}}. \quad (2.11)$$

Menurut Jeff Heaton (2008), jumlah node pada *hidden layer* adalah:

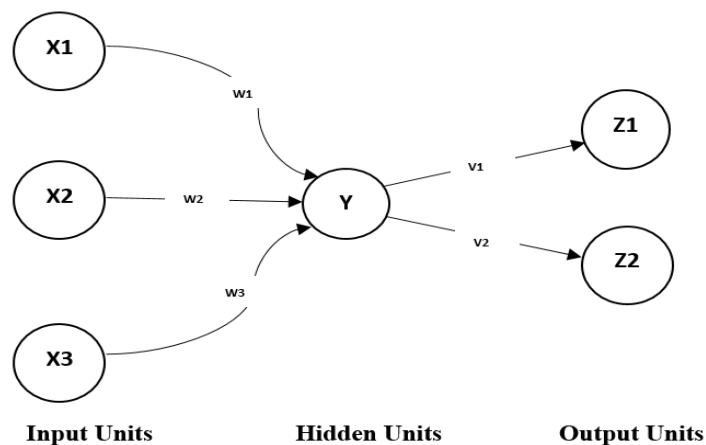
- Antara jumlah node *input layer* dan *output layer*;
- $2/3$ dari jumlah *input layer* ditambah dengan *output layer*;
- Kurang dari $2x$ *input layer*.

3) Lapis *output*

Unit-unit dalam lapisan *output* disebut unit-unit *output*. *Output* dari lapisan ini merupakan solusi *Artificial Neural Network* terhadap suatu permasalahan. Setelah melalui proses *training*, *network* merespon *input* baru untuk menghasilkan *output* yang merupakan hasil peramalan.

2.4.1 Arsitektur *Artificial Neural Network*


Pengaturan *neuron* ke dalam lapisan, pola hubungan dalam lapisan, dan di antara lapisan disebut arsitektur *artificial neural network* (Fausset, 1994). Arsitektur jaringan *artificial neural network* diilustrasikan dalam gambar 6 yang terdiri dari unit *input*, unit *output*, dan satu unit tersembunyi. *Artificial neural network* sering diklasifikasikan sebagai *single layer* dan *multilayer*.



Gambar 6. Arsitektur jaringan *artificial neural network* sederhana.

1. *Single layer*

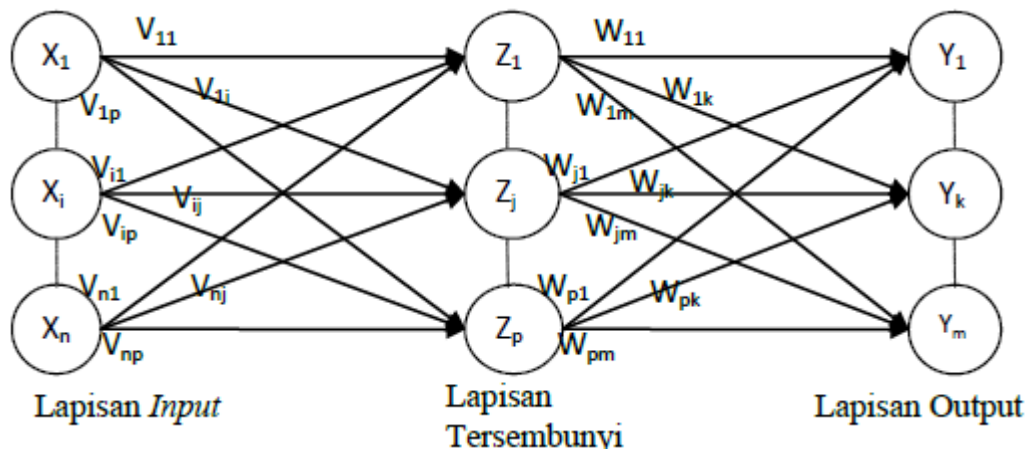
Sebuah jaringan *single layer* memiliki satu lapisan bobot koneksi (Fausset, 1994). Ciri khas dari *single layer* terlihat dalam gambar 7, dimana unit *input* yang menerima sinyal dari dunia luar terhubung ke unit *output* tetapi tidak terhubung ke unit *input* lain, dan unit-unit *output* yang terhubung ke unit *output* lainnya.



Gambar 7. Arsitektur jaringan *artificial neural network single layer*.

2. *Multilayer*

Jaringan *multilayer* adalah jaringan dengan satu arah atau lebih lapisan tersembunyi antara unit *input* dan unit *output* (Fausset, 1994). Biasanya, ada lapisan bobot antara dua tingkat yang berdekatan unit (*input*, tersembunyi, atau *output*). Jaringan *multilayer* yang diilustrasikan pada gambar 8 dapat memecahkan masalah yang lebih rumit daripada jaring *single layer*. Namun, proses pelatihan sering membutuhkan waktu yang cenderung lama tentu dengan pembelajaran yang lebih rumit.



Gambar 8. Arsitektur jaringan *artificial neural network multilayer*.

2.4.2 Fungsi Aktivasi

Menurut Siang (2009) dalam *artificial neural network*, fungsi aktivasi digunakan untuk menentukan keluaran suatu *neuron*. Fungsi aktivasi untuk algoritma *backpropagation* harus memiliki beberapa karakteristik penting (Fausett, 2014), yaitu:

- a. Harus kontinu.
- b. Terdifferensial.
- c. Monoton.


Ada beberapa fungsi aktivasi yang memenuhi karakteristik di atas yaitu:

1. Fungsi Aktivasi *Logistic*

Fungsi ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode *Backpropagation*. Fungsi *logistic* memiliki nilai pada range 0 sampai 1. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai *output* yang terletak pada interval 0 sampai 1. Namun, fungsi ini bisa juga digunakan oleh jaringan syaraf yang nilai outputnya 0 atau 1. Fungsi *logistic* dirumuskan sebagai:

$$y = f(x) = \frac{1}{1+e^{-x}} \quad (2.12)$$

$$\text{dengan: } f'(x) = f(x)[1 - f(x)] \quad (2.13)$$



Gambar 9. Fungsi Aktivasi *logistic*.


2. Fungsi Aktivasi ReLU (*Rectified Linear Unit*)

ReLU merupakan fungsi aktivasi bertanggung jawab untuk menormalisasikan nilai yang dihasilkan *convolutional Layer*, misalkan pada fungsi aktivasi *rectifier* menormalisasikan nilai sehingga tidak ada nilai yang di bawah 0 dengan menggunakan fungsi $\max(0, x)$. Apabila terdapat matriks *input* x maka diperoleh nilai ReLU pada persamaan (2.14):

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.14)$$

Pada tahap *backpropagation*, digunakan turunan fungsi aktivasi untuk memperoleh nilai gradient *input*. Berdasarkan persamaan (2.14) maka diperoleh persamaan turunan pada persamaan (2.15):

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.15)$$



Gambar 10. Fungsi Aktivasi ReLU (*Rectified Linear Unit*).


3. Fungsi Aktivasi *Leaky* ReLU

Leaky ReLU ini digunakan untuk menyelesaikan masalah di ReLU. *Leaky* membantu untuk menambah range dari ReLU. Biasanya nilai dari α adalah 0.01. Ketika α tidak bernilai 0.01 maka dinamakan sebagai *Randomized* ReLU. *Leaky* ReLU memiliki nilai range -tak hingga sampai tak hingga, dan dapat memastikan nilai negatif tidak menjadi 0. *Leaky* ReLU keduanya adalah monotonik, jadi derivatif keduanya juga monotonik.

$$f(x) = \begin{cases} x & , x \geq 0 \\ \alpha x & , x < 0 \end{cases} \quad (2.16)$$

Dengan,

$$f'(x) = \begin{cases} 1 & , x \geq 0 \\ \alpha & , x < 0 \end{cases} \quad (2.17)$$




Gambar 11. Fungsi Aktivasi *Leaky* ReLU.

4. Fungsi Aktivasi Tanh

Fungsi tangen hiperbolik berhubungan erat dengan fungsi *sigmoid bipolar* yang juga sering digunakan sebagai fungsi aktivasi ketika jangkauan yang diharapkan dari nilai output diantara -1 dan 1 . Persamaan fungsi *sigmoid bipolar* adalah:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.18)$$



Gambar 12. Fungsi Aktivasi Tanh.


5. Fungsi Aktivasi ELU (*Exponential Linear Unit*)

Unit Linear Eksponential memiliki nilai negatif yang mendorong rata-rata aktivasi mendekati nol. Aktivasi rata-rata yang mendekati nol memungkinkan pembelajaran lebih cepat karena membawa gradient lebih dekat ke gradient alami. Fungsi aktivasi ELU dirumuskan sebagai berikut:

$$f(x) = \begin{cases} x & , x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (2.19)$$

dengan,

$$f'(x) = \begin{cases} 1 & , x \geq 0 \\ f(x) + \alpha, & x < 0 \end{cases} \quad (2.20)$$



Gambar 13. Fungsi Aktivasi ELU.

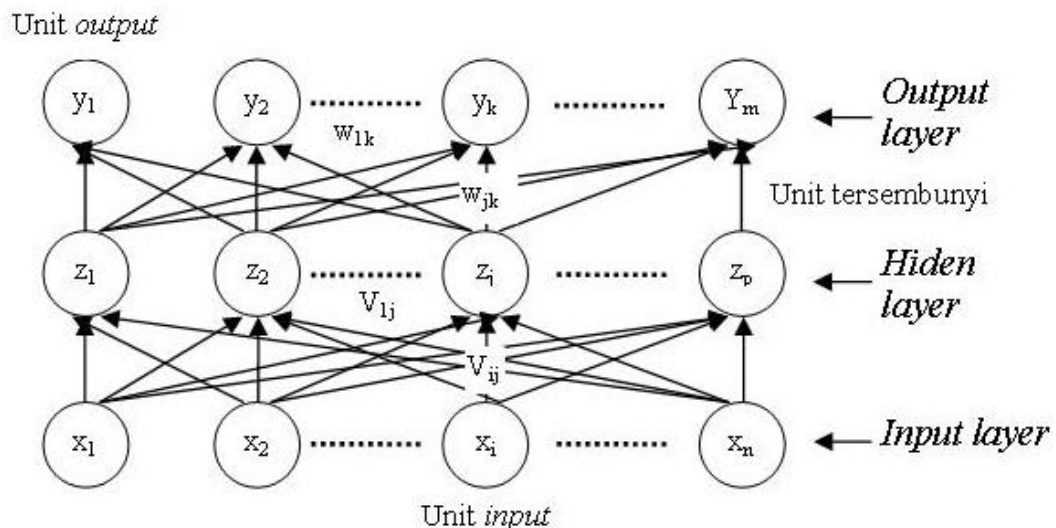
2.4.3 *Backpropagation* pada *Artificial Neural Network*

Seperti yang telah dijelaskan *artificial neural network* menyerupai otak manusia dalam dua hal, salah satunya adalah pengetahuan diperoleh jaringan melalui proses belajar. *Artificial neural network* akan mencoba untuk mensimulasikan kemampuan otak manusia untuk belajar. *Artificial neural network* juga tersusun atas *neuron-neuron* dan *dendrit*. Tidak seperti model biologis, *artificial neural network* memiliki struktur yang tidak dapat diubah, dibangun oleh sejumlah *neuron*, dan memiliki nilai tertentu yang menunjukkan seberapa besar koneksi antara *neuron* (yang dikenal dengan nama bobot). Perubahan yang terjadi selama proses pembelajaran adalah perubahan nilai bobot. Nilai bobot akan bertambah, jika informasi yang diberikan oleh *neuron* yang bersangkutan tersampaikan, sebaliknya jika informasi tidak disampaikan oleh *neuron* ke *neuron* yang lain, maka nilai bobot yang menghubungkan keduanya akan dikurangi. Pada saat pembelajaran dilakukan pada *input* yang berbeda, maka nilai bobot akan diubah secara dinamis hingga mencapai suatu nilai yang cukup seimbang. Apabila nilai ini telah tercapai mengindikasikan bahwa tiap-tiap *input* telah berhubungan dengan *output* yang diharapkan (Kristanto, 2004).

Backpropagation atau propagasi balik merupakan suatu teknik pembelajaran atau pelatihan *supervised learning* yang paling banyak digunakan. Metode ini

merupakan salah satu metode yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks. Di dalam jaringan propagasi balik ini, setiap unit yang berada di lapisan *input* terhubung dengan setiap unit yang ada di lapisan *output*. Jaringan ini terdiri dari banyak lapisan. Ketika jaringan diberikan pola masukan sebagai pola pelatihan, maka pola tersebut menuju unit-unit lapisan tersembunyi untuk selanjutnya diteruskan pada unit-unit di lapisan keluaran. Kemudian unit-unit lapisan keluaran akan memberikan respon sebagai keluaran *artificial neural network*. Saat hasil keluaran tidak sesuai dengan yang diharapkan, maka keluaran akan disebarkan mundur pada lapisan tersembunyi kemudian dari lapisan tersembunyi menuju lapisan masukan (Puspitaningrum, 2006).

Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur. Untuk mendapat *error* ini, tahap perambatan maju harus dikerjakan terlebih dahulu. Pada saat perambatan maju, *neuron-neuron* diaktifkan dengan menggunakan fungsi aktivasi.



Gambar 14. Arsitektur Jaringan *Backpropagation*.

Model *Feedforward neural network* algoritma *backpropagation* secara sistematis dapat dituliskan sebagai berikut:

$$y_k = \sum_{j=1}^p w_{kj} \cdot f[v_{j0} + \sum_{i=1}^n x_i v_{ji}] + w_{k0} \quad (2.21)$$

2.5 Investasi Emas

Pada umumnya orang memilih berinvestasi dalam bentuk emas untuk memperoleh keuntungan (Diantoro, 2010). Investasi emas dibedakan menjadi 2 yaitu, emas batangan dan saham emas (sertifikat). Keduanya mempunyai peluang investasi dan resiko masing-masing. Berinvestasi dalam emas batangan membutuhkan biaya untuk menyewa *safe deposit box* dan memungkinkan resiko lebih besar daripada berinvestasi emas dalam bentuk saham. Dalam berinvestasi emas berbentuk saham, investor hanya perlu keahlian membaca bursa saham. Dalam penelitian ini, penulis meramalkan harga emas yang diperoleh dari *website Investing*.

Emas memiliki *supply* yang terbatas dan tidak mudah didapat, sementara permintaan terhadap emas tidak pernah berkurang, akibatnya harga emas cenderung mengalami kenaikan dari tahun ke tahun (Diantoro, 2010). Harga emas yang dijadikan standar harga emas seluruh negara di dunia adalah harga emas yang ditentukan oleh *London Bullion Market Association (LBMA)* dengan sistem *London Gold Fixing*. LBMA menentukan harga emas dua kali dalam sehari setiap hari kerja, yaitu pukul 10.30 (*Gold A.M*) dan pukul 15.00 (*Gold P.M*) dengan mata uang Dolar Amerika Serikat per *troy ounce*. Harga yang digunakan sebagai patokan harga emas seluruh negara di dunia adalah harga *Gold P.M*. (LBMA, 2015).

Pada kenyataan sehari-hari, harga emas tidak hanya bergantung kepada situasi permintaan dan penawaran. Harga emas juga dipengaruhi oleh situasi perekonomian secara keseluruhan. Faktor-faktor yang mempengaruhi harga emas sebagai berikut (Diantoro, 2010):

1. Inflasi

Inflasi terjadi jika nilai mata uang mengalami penurunan sehingga harga barang di pasaran mengalami kenaikan. Hal ini didorong oleh meningkatnya permintaan barang dan jasa yang kemudian diperparah dengan tersendatnya distribusi barang. Kondisi inflasi seperti inilah yang mendorong naiknya harga emas.

2. Krisis finansial

Saat terjadi krisis finansial, orang lebih jeli dalam berinvestasi. Orang akan mencari keamanan dalam berinvestasi, sehingga mereka akan memilih investasi yang memberikan keuntungan. Dalam hal ini adalah berinvestasi dengan emas.

3. Naiknya permintaan emas di pasaran

Harga emas dapat naik karena permintaan akan emas dipasaran yang mengalami peningkatan.

4. Kurs dollar

Karena harga emas dihitung berdasarkan kurs dollar, maka jika dollar mengalami kenaikan, harga emas akan ikut terdorong naik.

5. Harga minyak

Pada korelasi antara emas dan minyak, mereka memiliki hubungan berbanding lurus. Jika harga minyak melonjak, hal ini menyebabkan produksi emas akan menurun dikarenakan biaya produksi semakin mahal. Penambangan emas sangatlah bergantung pada minyak untuk operasionalnya. Pada situasi lain, ketika harga minyak melonjak naik, kinerja perusahaan akan menurun. Produksi mereka pun menurun dan bisa jadi tidak mencapai target. Hal ini menyebabkan banyak para investor dari perusahaan tersebut yang melepas kepemilikan sahamnya. Hal ini menyebabkan harga emas perusahaan itu pun melorot. Para investor pun mencari alternatif lain untuk mengembangkan finansial mereka, salah satunya emas. Permintaan yang tinggi terhadap emas di saat para investor melepas kepemilikan sahamnya menyebabkan harga emas merangkak naik.

6. Situasi politik dunia

Kenaikan harga emas pada akhir tahun 2002 dan awal tahun 2003 terjadi karena sekutu yang dikomando AS akan melakukan serangan ke Iraq. Pelaku pasar beralih investasi dari pasar uang dan pasar saham ke investasi emas sehingga permintaan emas melonjak tajam.

2.6 Akurasi Model

Menurut Makridakis dkk. (1999), “ketepatan (*accuracy*)” menunjukkan seberapa jauh model peramalan tersebut mampu mereproduksi data yang telah diketahui. Dalam pemodelan *time series*, sebagian data yang diketahui dapat digunakan untuk meramalkan sisa data berikutnya, sehingga memungkinkan orang untuk mempelajari ketepatan ramalan secara lebih langsung. Ukuran ketepatan model biasanya menggunakan faktor kesalahan galat yang diperoleh dari perbedaan antara data aktual dan hasil ramalan pada period ke-t atau dapat dinyatakan dengan:

$$e_t = X_t - F_t \quad (2.22)$$

dimana: e_t = kesalahan ramalan pada periode t

F_t = nilai ramalan untuk periode t

X_t = data atau nilai aktual pada periode t

Jika terdapat nilai pengamatan dan ramalan untuk n periode waktu, maka akan terdapat n galat. Dari galat tersebut diperoleh suatu ukuran yang digunakan seperti:

a. Nilai Tengah Galat atau *Mean Error*

$$\begin{aligned} ME &= \sum_{i=1}^n \frac{e_t}{n} \\ &= \frac{\sum_{i=1}^n X_t - F_t}{n} \end{aligned} \quad (2.23)$$

b. Nilai Tengah Galat atau *Mean Absolute Error*

$$\begin{aligned} MAE &= \sum_{i=1}^n \frac{|e_t|}{n} \\ &= \sum_{i=1}^n \frac{|X_t - F_t|}{n} \end{aligned} \quad (2.24)$$

c. Nilai Galat atau *Sum of Error*

$$\begin{aligned} SE &= \sum_{i=1}^n e_t \\ &= \sum_{i=1}^n (X_t - F_t) \end{aligned} \quad (2.25)$$

d. Nilai Kuadrat Galat atau *Sum of Squared Error*

$$\begin{aligned} SSE &= \sum_{i=1}^n e_t^2 \\ &= \sum_{i=1}^n (X_t - F_t)^2 \end{aligned} \quad (2.26)$$

- e. Nilai Tengah Galat Kuadrat atau *Mean of Squared Error*

$$\begin{aligned} MSE &= \sum_{i=1}^n \frac{e_t^2}{n} \\ &= \sum_{i=1}^n \frac{(X_t - F_t)^2}{n} \end{aligned} \quad (2.27)$$

- f. Nilai Standar Galat atau *Standart Deviation of Error*

$$\begin{aligned} SDE &= \sqrt{\sum_{i=1}^n \frac{e_t^2}{n-1}} \\ &= \sqrt{\sum_{i=1}^n \frac{(X_t - F_t)^2}{n-1}} \end{aligned} \quad (2.28)$$

Ketepatan dari suatu model peramalan dapat dilihat berdasarkan ukuran-ukuran di atas. Sebagai contoh adalah untuk tujuan optimalisasi statistik seringkali memilih suatu model dengan nilai *mean square error* dan *sum square error* minimal. Karena dengan *mean square error* dan *sum square error* minimal menunjukkan model yang diperoleh memberikan hasil ramalan yang nilainya hampir sama dengan data aktual (Makridakis dkk, 1999).

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2020/2021 bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Spesifikasi Komputer

Pada penelitian ini, peneliti menggunakan komputer dengan spesifikasi sebagai berikut:

- Teknologi PC3-10600 Non_Parity(NP) Double Data Rate Tiga (DDR3).
- Prosesor Intel (R) Core™ i3 i3-2310M dengan dual core.
- Pengontrol memori DDR3 (hingga 1333MHz), Intel Turbo Boost, teknologi Hyper-Threading; Tomblok 3MB.
- 4GB RAM.
- Konektor Ethernet RJ-45 untuk koneksi LAN.
- IEEE 1394 FireWire 400.
- Sistem Operasi Windows 7 Home Premium (64-bit).

3.3 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari *website* Investing (<https://id.investing.com/>). Data sekunder adalah data penelitian yang sudah tersedia dan dikumpulkan oleh pihak lain (Anwar, 2014). Data tersebut merupakan data harian harga emas dunia dalam USD/*trounce* pada tahun 2013-2021 dengan menggunakan hari aktif sebanyak 2099 data. Sebanyak 80% dari data digunakan untuk data *training* dan 20% dari data

digunakan untuk data *testing*. Proses pelatihan ini menggunakan R Studio versi 4.0.

3.4 Metode Penelitian

Tahapan metode *Backpropagation* adalah sebagai berikut:

- a. Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil).
- b. Tetapkan : maksimum *Epoch*, target *Error*, dan *Learning Rate* (α).
- c. Inisialisasi : $Epoch = 0$, $mean\ square\ error = 1$.

Siang (2009) menyatakan bahwa algoritma pelatihan untuk jaringan *backpropagation* adalah sebagai berikut:

Langkah 1 : Menetapkan nilai *input*.

Langkah 2 : Membuat inisialisasi semua bobot dengan bilangan acak kecil (Siang, 2009).

Fase I : Propagasi Maju (*Forward Propagation*)

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

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

$$Z_{in_j} = V_{oj} + \sum_{i=1}^n X_i V_{ij} \quad (3.1)$$

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

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

$$Y_{in_k} = W_{ok} + \sum_{j=1}^p Z_j W_{jk} \quad (3.2)$$

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

Fase II : Propagasi Mundur (*Backpropagation*)

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

$$\begin{aligned}\delta_k &= (t_k - Y_k)f(Y_{in_k}) \\ &= (t_k - Y_k)y_k(1 - Y_k)\end{aligned}\quad (3.3)$$

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

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (3.4)$$

Hitung koreksi nilai *bias* yang kemudian akan digunakan untuk memperbaharui nilai W_{ok} :

$$\Delta W_{ok} = \alpha \delta_k \quad (3.5)$$

Kirimkan δ_k ke unit-unit yang ada dilapisan bawahnya.

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

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \quad (3.6)$$

Kemudian nilai tersebut dikalikan dengan nilai turunan dari fungsi aktivasi untuk menghitung informasi kesalahan. Hitung koreksi nilai bobot yang kemudian digunakan untuk memperbaharui V_{ij} :

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (3.7)$$

Hitung juga koreksi *bias* (yang nantinya akan digunakan untuk memperbaiki nilai V_{oj}):

$$\Delta V_{jk} = \alpha \delta_j \quad (3.8)$$

Fase III : Perubahan Bobot

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

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (3.9)$$

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

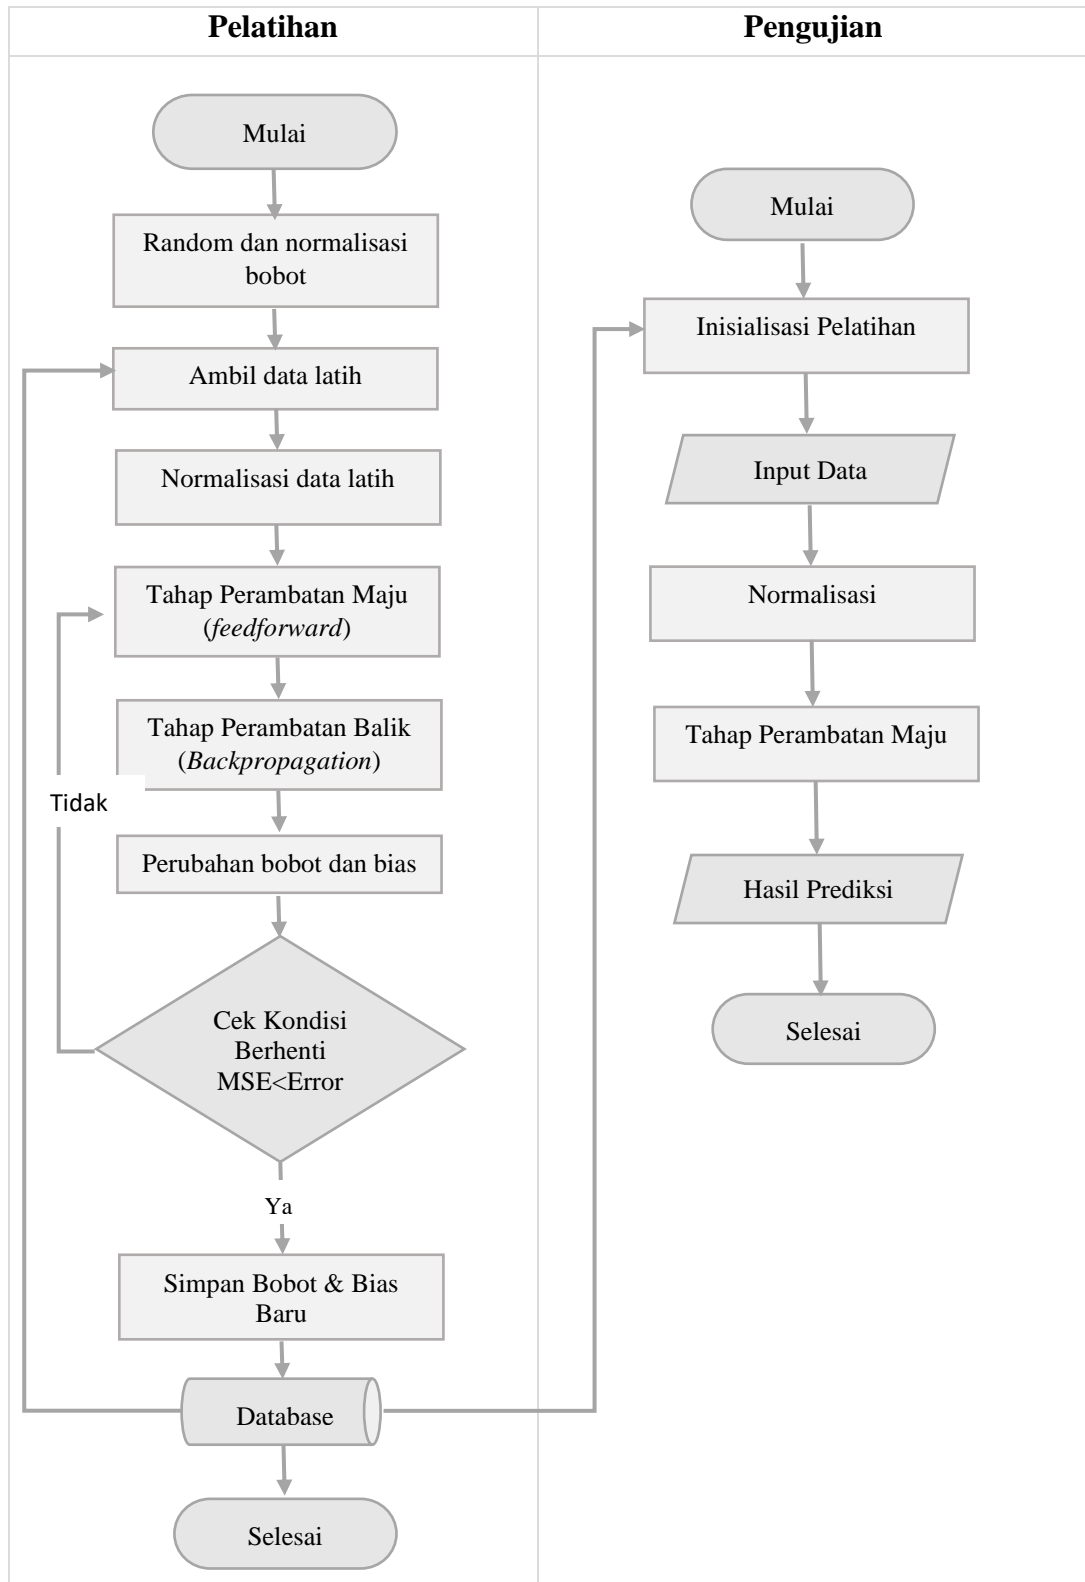
$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (3.10)$$

Langkah 9 : Menghitung *mean square error*, jika nilai *mean square error* belum lebih kecil daripada target *error*, maka langkah 2-8 terus dilakukan.

Keterangan simbol-simbol pada algoritma *artificial neural network backpropagation* dijelaskan pada tabel 1 sebagai berikut:

Tabel 1. Simbol-simbol Algoritma *Backpropagation*

No.	Simbol	Keterangan
1	X	<i>Input</i> vektor pelatihan, $X_i (i = 1, 2, 3, \dots, n)$
2	Y	<i>Output</i> vector target, $Y_k (k = 1, 2, 3, \dots, m)$
3	δ_k	Informasi tentang kesalahan pada unit Y_k yang disebarkan kembali ke unit tersembunyi
4	δ_j	Informasi tentang kesalahan dari lapisan <i>output</i> ke unit tersembunyi Z_j
5	α	Laju pembelajaran (<i>learning rate</i>)
6	X_i	Unit <i>input</i> i
7	V_{oj}	<i>Bias</i> pada lapisan tersembunyi j
8	Z_j	Unit tersembunyi j
9	Z_in_j	<i>Input</i> jaringan ke Z_j
10	V_{ok}	<i>Bias</i> pada unit tersembunyi k
11	Y_k	Unit <i>output</i> i
12	Y_in_k	<i>Input</i> jaringan ke Y_k



Gambar 15. Flowchart Sistem Pelatihan dan Pengujian Algoritma Backpropagation.

V. KESIMPULAN

Berdasarkan pembahasan mengenai pembentukan model *Feedforward Neural Network* dengan algoritma *Backpropagation* yang diterapkan untuk meramalkan harga open emas, maka dapat disimpulkan sebagai berikut:

1. Prosedur pembentukan model *Feedforward neural network* dengan algoritma *Backpropagation* pada data *time series* terdiri atas beberapa tahap, yaitu (1) menentukan input, (2) melakukan pembagian data menjadi 2 yaitu data *training* dan data *testing*, (3) normalisasi data, (4) membangun model *Feedforward neural network* dengan algoritma *Backpropagation*, yaitu menentukan banyaknya neuron pada lapis tersembunyi, menentukan input, dan menentukan bobot model, (5) denormalisasi dan (6) uji kesesuaian model.
2. Model FFNN dengan algoritma BP ini diterapkan pada data harga emas tanggal 1 Februari 2013 sampai 1 Februari 2021 dengan variabel *input* yang digunakan yaitu harga open emas Lag 1, Lag 2, dan Lag 3. Berdasarkan hasil numerik pada Tabel 3 serta plot yang dihasilkan pada Lampiran II, struktur jaringan terbaik yang diperoleh adalah dengan 3 *neuron input*, 5 *neuron* pada lapis tersembunyi pertama dan 4 *neuron* pada lapis tersembunyi kedua dengan menggunakan fungsi aktivasi Tanh.
3. Peramalan harga emas tersebut menghasilkan MAPE sebesar 0.74% (kurang dari 10%), maka dapat disimpulkan bahwa keakuratan hasil peramalan sangat baik. Hasil peramalan untuk 10 periode ke depan menghasilkan error terkecil pada 9 Februari 2021 yaitu sebesar 1.491, dan error terbesar pada tanggal 5 Februari 2021 sebesar 47.518.

DAFTAR PUSTAKA

DAFTAR PUSTAKA

- Azam, D.F., Ratnawati, D.E., dan Adikara, P.P. 2018. Prediksi Harga Emas Batang Menggunakan Feedforward Neural Network Dengan Algoritma Genetika. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer* 2(8): 2317-2322.
- Bambang, B., Widodo, R.J., Sतालaksana, I.Z., dan Singgih, M.L. 2004. Teknik Jaringan Syaraf Tiruan Feedforward Untuk Prediksi Harga Saham Pada Pasar Modal Indonesia. *Jurnal Teknik Informatika* 1(1): 11-22.
- Diantoro, Y. 2010. *EMAS – Investasi dan Pengolahannya*. Gramedia Pustaka Utama, Jakarta.
- Fausett, L. 1994. *Fundamental of Neural Network (Archetectors, Algorithms, and Applications)*. Prentice-Hall, New-Jersey.
- Ghufran, M., Adiwijaya, dan Faraby, S.A. 2018. Penerapan Particle Swarm Optimization Pada Feedforward Neural Network Untuk Klasifikasi Teks Hadis Bukhari Terjemahan Bahasa Indonesia. *Jurnal Teknik Informatika* 2(4): 165-173.
- Hanke, J.E. dan Winchern, D.W. 2004. *Business Forecasting Eight Edition*. Prentice-Hall, New Jersey.
- Heaton, J. 2008. *Introduction to Neural Networks with Java Second Edition*. Heaton Research, United States of Amerika.
- Irsalinda, N. dan Astuti, Y.S. 2020. Fuzzy Feedforward Neural Network (FFFNN) Model for the Jakarta Islamic Index (JII) Forecasting. *Jurnal Rekayasa dan Teknologi Terapan* 1(1): 1-10.
- James, G., Witten, D., Hastie, T., dan Tibshirani, R. 2013. *An Introduction to Statistical Learning with Applications in R*. Pearson Education, New York.
- Kencana, C.W., Setiawan, E.B., dan Kurniawan, I. 2020. Hoax Detection on Twitter using Feedforward and Backpropagation Neural Networks Method. *Jurnal Rekayasa Sistem dan Teknologi Informasi* 4(4): 648-654.
- Khashei, M., dan Bijari, M. 2010. An Artificial Neural Network (p, d, q) model for time series forecasting. *International Journal of Expert System with Applications* 37: 479-489.

- Kristanto, A. 2004. *Jaringan Syaraf Tiruan, Konsep Dasar, Algoritma dan Aplikasinya*. Gava Media, Yogyakarta.
- Lewis, N., D. 2017. *Neural Network For Time Series Forecasting With R*. Pearson Education, New York.
- London Bullion Market Association. 2015. LBMA Gold Price. <http://www.lbma.org.uk/lbma-gold-price>. 10 Januari 2021 (10:23).
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan*. Edisi ke-2. Jilid 1. Erlangga, Jakarta.
- Nurmila, N., Sugiharto, A., dan Sarwoko, E.A. 2016. Algoritma Backpropagation Neural Network Untuk Pengenalan Pola Karakter Huruf Jawa. *Jurnal Teknik Informatika* 1(1): 1-10.
- Pakaja, F., Naba, A., dan Purwanto. 2012. Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor. *Jurnal Teknik Informatika* 6(1): 23-28.
- Puspitaningrum, D. 2006. *Pengantar Jaringan Syaraf Tiruan*. Penerbit ANDI, Yogyakarta.
- Siang, J.J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Penerbit ANDI, Yogyakarta.
- Tealab, A. 2018. Time Series Forecasting Using Artificial Neural Networks Methodologies: A Systematic Review. *International Journal of Future Computing and Informatics* 3: 334-340.
- Wang, L., Zou, H., Su, J., Li, L., dan Chaundhry, S. 2013. An ARIMA-ANN Hybrid Model for Time Series Forecasting. *International Journal of Systems Research and Behavioral Science* 30: 244-259.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods Second Edition*. Pearson Education, New York.
- Yuliandar, D., Warsito, B., dan Yasin, H. 2012. Pelatihan Feedforward Neural Network Menggunakan Algoritma Genetika Dengan Metode Seleksi Turnamen Untuk Data Time Series. *Jurnal Gaussian* 1(1): 65-72.