

TESIS

**PERBANDINGAN METODE *ARTIFICIAL NEURAL NETWORK*
BACKPROPAGATION DAN GARCH DALAM
MEMPREDIKSI HARGA SAHAM
(Studi Kasus : Saham Indosat Tahun 2012 – 2022)**

*COMPARISON OF ARTIFICIAL NEURAL NETWORK
BACKPROPAGATION AND GARCH METHODS
IN PREDICTING STOCK PRICE
(Case Study: Indosat Shares 2012 – 2022)*



MAKTISEN ENA

H062202004

**PROGRAM STUDI MAGISTER STATISTIKA
DEPARTEMEN STATISTIK
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2022**

**PERBANDINGAN METODE *ARTIFICIAL NEURAL NETWORK*
BACKPROPAGATION DAN GARCH DALAM
MEMPREDIKSI HARGA SAHAM
(Studi Kasus : Saham Indosat Tahun 2012 – 2022)**

Tesis

Sebagai salah satu syarat untuk mencapai gelar magister

Program Studi Magister Statistika

Disusun dan diajukan oleh

MAKTISEN ENA

H062202004

**PROGRAM STUDI MAGISTER STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2022**

TESIS

PERBANDINGAN METODE *ARTIFICIAL NEURAL NETWORK*
BACKPROPAGATION DAN GARCH DALAM
MEMPREDIKSI HARGA SAHAM
(Studi Kasus : Saham Indosat Tahun 2012 – 2022)

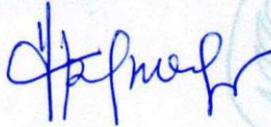
MAKTISEN ENA

H062202004

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka
Penyelesaian Program Studi Magister Statistika Fakultas Matematika dan Ilmu
Pengetahuan Alam Universitas Hasanuddin
pada tanggal 24 Januari 2023
dan dinyatakan telah memenuhi syarat kelulusan

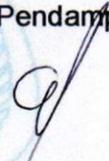
Menyetujui,

Pembimbing Utama,



Dr. Erna Tri Herdiani, S.Si., M.Si
NIP.19750429 200003 2 001

Pembimbing Pendamping



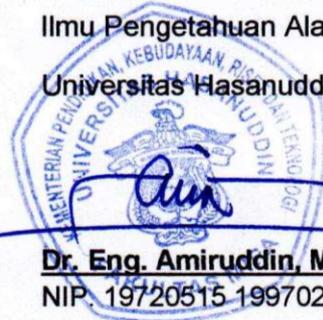
Dr. Dr. Georgina Maria Tinungki, M.Si
NIP. 19620926 198702 2 001

Ketua Program Studi
Magisten Statistik,



Dr. Dr. Georgina Maria Tinungki, M.Si
NIP.19750429 200003 2 001

Dekan Fakultas Matematika dan
Ilmu Pengetahuan Alam
Universitas Hasanuddin,



Dr. Eng. Amiruddin, M.Si
NIP. 19720515 199702 1 002

PERNYATAAN KEASLIAN TESIS DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa, tesis berjudul Perbandingan Metode *Artificial Neural Network Backpropagation* dan GARCH dalam Memprediksi Harga Saham (Studi Kasus: Saham Indosat Tahun 2012 – 2022) adalah benar karya saya dengan arahan dari komisi pembimbing (Dr. Erna Tri Herdiani, S.Si., M.Si dan Dr. Dr. Georgina Maria Tinungki, M.Si). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari isi tesis ini telah dipublikasikan di Jurnal (International Research Journal of Advanced Engineering and Science (IRJAES) ISSN: 2455-9024 Vol. 7 Issue 3, September - 2022, Pages:262-265) sebagai artikel dengan judul "*The Application of the Arima-Garch Method in Predicting the Indosat Stock Price*".

Dengan ini saya melimpahkan hak cipta dari karya tulis saya berupa tesis ini kepada Universitas Hasanuddin.

Makassar, 24 Januari 2022

Yang Menyatakan,



Maktisen Ena

NIM. H062202004

UCAPAN TERIMA KASIH

Puji syukur atas kehadiran Tuhan Yang Maha Esa atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyusun dan menyelesaikan tesis ini. Penulis menyadari sepenuhnya bahwa apa yang dikemukakan dalam tesis ini masih jauh dari kesempurnaan yang merupakan sebagai akibat dari keterbatasan kemampuan serta berbagai kesulitan yang penulis hadapi dalam menyusun tesis ini.

Penulis memanjatkan doa kepada Tuhan Yang Maha Esa agar memberikan rahmat-Nya kepada pihak yang banyak membantu dalam penyelesaian tesis ini. Penulis juga percaya tesis ini dapat selesai bukan hanya dengan kekuatan pikiran penulis semata akan tetapi karena bantuan dari berbagai pihak juga, baik selama proses perkuliahan bahkan sampai proses pengerjaan tesis di Program Magister Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Hasanuddin. Namun demikian, penulis dengan senang hati menerima kritik dan saran yang bersifat membangun dari pembaca karya tulis ini demi sempurnanya tesis ini.

Terima kasih yang tak terhingga kepada kedua orang tua tercinta dan saudariku atas doa yang tak pernah putus, dukungan serta segala kebaikan mereka yang sampai kapan pun takkan pernah bisa terbalaskan atas kasih sayang yang tiada henti dalam penyelesaian tesis ini. Selanjutnya, saya ingin menyampaikan juga rasa hormat dan terima kasih kepada:

1. **Prof. Dr. Ir. Jamaluddin Jompa, M.Sc.** selaku Rektor Universitas Hasanuddin.
2. **Dr. Eng. Amiruddin, M.Si.** selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam beserta seluruh jajarannya.
3. **Dr. Nurtiti Sanusi, M.Si.** selaku Ketua Departemen Statistika yang menjadi salah satu tim penguji tesis sekaligus memberikan ilmu, dukungan, dan motivasi serta kemudahan kepada penulis dalam berbagai hal selama menjalani Pendidikan di Departemen Statistika.
4. **Dr. Dr. Georgina Maria Tinungki, M.Si.** selaku Ketua Program Studi Magister Statistika yang menjadi Pembimbing Pertama yang telah bersabar dan bersedia meluangkan banyak waktunya untuk membimbing penulis dan memberikan masukan dalam penyelesaian tesis ini.

5. **Dr. Erna Tri Herdiani, M.Si** selaku Pembimbing Utama yang telah bersabar dan bersedia meluangkan banyak waktunya untuk membimbing penulis dan memberikan masukan dalam penyelesaian tesis ini.
6. **Dr. Nirwan Ilyas, M.Si** selaku penguji penulis yang telah bersedia memberikan masukan-masukan dan arahan dalam penyusunan tesis.
7. **Dr. Anna Islamiyati, S.Si., M.Si** selaku penguji penulis yang telah bersedia memberikan masukan-masukan dan arahan dalam penyusunan tesis.
8. Ibunda **Sulfina Ena** yang telah mendidik dan membesarkan penulis dengan penuh cinta, kasih, sayang serta dengan ikhlas telah mengiringi setiap langkah penulis dengan do'a dan restunya.
9. Istri tercinta **Jane M. Tefi** dan kedua buah hati kembar **Mark Kristofel Orlando Ena** dan **Matthew Kristofel Erlando Ena** terima kasih atas dukungan, do'a serta motivasi dan memberikan semangat tiada henti kepada penulis.
10. **K. Johan** dan penghuni **Pondok Boba** yang telah berkontribusi besar dengan saling mengingatkan dalam kebaikan dan saling memotivasi. Saya ucapkan terima kasih.
11. Teman-teman **Lab** yaitu **Agung Muhammad Takdir, Ratmila, Ainun Utari, Samsir** dan **Ummul** atas doa, semangat serta kebersamaannya selama ini yang banyak membantu penulis.
12. Hedi Kuswanto dan teman – teman Mahasiswa Program Magister Statistika Angkatan 3 terima kasih atas dukungan luar biasa kepada penulis.

Semoga Allah SWT memberikan pahala yang berlipat ganda atas segala kebaikan yang telah diberikan kepada penulis dan semoga penulisan tesis ini bermanfaat bagi perkembangan ilmu pengetahuan dan teknologi, khususnya dalam dunia statistika dan data sains.

Makassar, 24 Januari 2023

Maktisen Ena

ABSTRAK

MAKTISEN ENA. **Perbandingan Metode *Artificial Neural Network Backpropagation* dan GARCH dalam Memprediksi Harga Saham (Studi Kasus: Saham Indosat Tahun 2012 – 2022)** (dibimbing oleh Dr. Erna Tri Herdiani, S.Si., M.Si dan Dr. Dr. Georgina Maria Tinungki, M.Si).

Salah satu masalah yang dihadapi dalam proses peramalan adalah masalah heteroskedastisitas. Heteroskedastisitas banyak terjadi terutama pada data saham. Harga Saham Pt. Indosat (tbk) dari tanggal 6 Maret 2012 – 18 Januari 2022 mengalami fluktuatif dari waktu ke waktu, sehingga variannya bersifat heteroskedastisitas. *Model Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) dan *Artificial Neural Network Backpropagation* (ANNBP) merupakan metode yang dapat digunakan pada data yang mengalami heteroskedastisitas. Tujuan dalam penelitian untuk memperoleh model dan hasil peramalan dari GARCH dan ANN Backpropagation. Dalam penelitian ini, kedua model tersebut dibandingkan berdasarkan nilai MAPE terkecil. Penelitian ini menggunakan data harian penutupan Saham Indosat. Peramalan dilakukan pada data penutupan saham Indosat, jumlah data 2453 data dibagi dalam dua bagian yaitu data latih 80% berjumlah 1962 data dan 20% data latih berjumlah 491 data. Hasil peramalan dari model GARCH diperoleh nilai MAPE sebesar 11.04%, dan model ANN Backpropagation dengan 7 inputan layer, 20 *hidden layer*, diperoleh nilai MAPE sebesar 7.01%. dengan demikian, model terbaik untuk memprediksi Harga Saham Indosat dalam penelitian ini adalah model *backpropagation*.

Kata kunci: ARIMA, *Artificial Neural Network Backpropagation*, GARCH, Heteroskedastisitas, Peramalan, Saham Indosat.

ABSTRACT

MAKTISEN ENA. **Comparison of Artificial Neural Network Backpropagation and Garch Methods in Predicting Stock Price (Case Study: Indosat Shares 2012–2022)**, (supervised by Dr. Erna Tri Herdiani, S.Si., M.Si and Dr. Dr. Georgina Maria Tinungki, M .Si).

One of the problems encountered in the forecasting process is the problem of heteroscedasticity. Heteroscedasticity occurs a lot, especially in stock data. Pt Share Price Indosat (tbk) from March 6 2012 – January 18 2022 has fluctuated from time to time, so the variance is heteroscedasticity. The Generalized Autoregressive Conditional Heteroskedasticity (GARCH) model and Artificial Neural Network Backpropagation (ANNBP) are methods that can be used on data with heteroscedasticity. The aim of this research is to obtain models and forecasting results from GARCH and ANN Backpropagation. In this study, the two models were compared based on the smallest MAPE value. This study uses daily data on the closing of Indosat shares. Forecasting is done on Indosat stock closing data, the total data is 2453 data divided into two parts, namely 80% training data totaling 1962 data and 20% training data totaling 491 data. Forecasting results from the GARCH model obtained a MAPE value of 11.04%, and the ANN Backpropagation model with 7 input layers, 20 hidden layers, obtained a MAPE value of 7.01%. Thus, the best model for predicting Indosat's share price in this study is the backpropagation model.

Keywords: ARIMA, Backpropagation Neural Networks, Forecasting, GARCH, Heteroscedasticity, Indosat Shares.

DAFTAR ISI

UCAPAN TERIMA KASIH.....	v
ABSTRAK.....	vii
ABSTRACT.....	viii
DAFTAR ISI	ix
DAFTAR TABEL.....	xi
DAFTAR GAMBAR.....	xii
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	4
1.3. Tujuan Penelitian	4
1.4. Manfaat Penelitian	4
1.5. Batasan Masalah	4
BAB II TINJAUAN PUSTAKA.....	5
2.1. Deret Waktu (Times Series).....	5
2.2. Deret Waktu Univariat.....	5
2.2.1. Stasioner	5
2.2.2. Autocorrelation Function (ACF)	7
2.2.3. Partial Autocorrelation Function (PACF)	7
2.2.4. ARIMA.....	8
2.2.5. Ukuran Ketepatan Peramalan	9
2.3. Artificial Neural Network (ANN).....	10
2.4. Konsep Dasar Artificial Neural Network	11
2.5. Arsitektur Artificial Neural Network	11
2.6. Backpropagation.....	12
2.7. Fungsi Aktivasi.....	20
2.8. Heteroskedastisitas.....	22
2.9. Generalized Autoregressive Conditional Heteroskedasticity (GARCH)	23
2.9.1. Estimasi Parameter GARCH	25
2.10. Harga Saham	27
2.11. Kerangka Konseptual	29
BAB III METODOLOGI PENELITIAN	30
3.1. Sumber Data.....	30
3.2. Identifikasi Variabel.....	30
3.3. Metode Analisis	30

3.3.1. GARCH	30
3.3.2. Artificial Neural Network Backpropagation	31
3.4. Diagram Alir	32
BAB IV HASIL DAN PEMBAHASAN	33
4.1. Deskripsi Data	33
4.1.1. Normalisasi Data	34
4.2. Identifikasi Kestasioneran Data	36
4.3. Permodelan ARCH – GARCH	39
4.3.1. Identifikasi Model ARIMA	39
4.3.2. Estimasi Parameter dan Signifikansi ARIMA	39
4.4. Model ARCH-GARCH	43
4.5. Peramalan dengan metode GARCH (1,0)	45
4.6. <i>Artificial Neural Network Backpropagation</i>	46
4.7. Analisis ANN Backpropagation	50
4.8. Inisialisasi Bobot	52
4.9. Melakukan Pelatihan dengan Backpropagation	54
4.10. Penentuan Model	65
4.11. Peramalan ANN Backpropagation	66
4.12. Perbandingan Hasil Peramalan	67
BAB V PENUTUP	69
5.1. Kesimpulan	69
5.2. Saran	69
DAFTAR PUSTAKA	70
Lampiran 1	76
Lampiran 2	77

DAFTAR TABEL

Tabel 4. 1 Data Penutupan Saham Indosat 2012-2022	33
Tabel 4. 2 Hasil Transformasi Penutupan Saham Indosat	35
Tabel 4. 3 pengujian Stasioner Data Saham.....	37
Tabel 4. 4 Pengujian Stasioner Data Saham Hasil Differencing.....	38
Tabel 4. 5 Hasil Uji Estimasi dan Signifikansi Model ARIMA	40
Tabel 4. 6 Uji efek ARCH-GARCH pada Model	43
Tabel 4. 7 Uji Autokorelasi Ljung Box pada Model	44
Tabel 4. 8 Estimasi Parameter Model GARCH	45
Tabel 4. 9 Kesalahan Prediksi Saham Penutupan Indosat.....	46
Tabel 4. 10 Dimensi Matriks Harga Penutupan saham	51
Tabel 4. 11 Hasil Pengujian data uji penutupan saham Indosat.....	51
Tabel 4. 12 Bias pada <i>Input Layer</i> Terhadap <i>Hidden Layer</i>	53
Tabel 4. 13 Bobot pada <i>Hidden Layer</i> Terhadap <i>Output Layer</i>	53
Tabel 4. 14 <i>Sinyal Input</i> dari <i>Input Layer</i> ke <i>Hidden Layer</i>	55
Tabel 4. 15 <i>Sinyal output</i> di <i>hidden layer</i>	56
Tabel 4. 16 Sinyal output di hidden layer	57
Tabel 4. 17 Sinyal output di output layer	58
Tabel 4. 18 Koreksi Bobot dan Bias di <i>Hidden Layer</i> Terhadap Output Layer....	58
Tabel 4. 19 Faktor Kesalahan di Unit tersembunyi.....	59
Tabel 4. 20 Aktivasi Kesalahan di Unit tersembunyi.....	60
Tabel 4. 21 Koreksi Bobot dan Bias Input Layer terhadap Output Layer	61
Tabel 4. 22 Bias Akhir pada <i>Input Layer</i> terhadap <i>Hidden Layer</i>	62
Tabel 4. 23 Bobot Akhir pada Input Layer terhadap Output Layer.....	62
Tabel 4. 24 Bias dan bobot Akhir pada <i>Input Layer</i> terhadap <i>Hidden Layer</i> iterasi ke- 50.000	63
Tabel 4. 25 Bobot dan bias Akhir pada <i>hidden layer</i> terhadap <i>Output Layer</i> iterasi ke- 50.000	64
Tabel 4. 26 Kesalahan Prediksi Saham Penutupan Indosat.....	66

DAFTAR GAMBAR

Gambar 2. 1 ANN dengan pembobot	10
Gambar 2. 2 Jaringan Layer Tunggal	11
Gambar 2. 3 Jaringan Layer Jamak	12
Gambar 2. 4 Jaringan Backpropagation	16
Gambar 2. 5 Fungsi Sigmoid Biner.....	21
Gambar 2. 6 Kerangka Konseptual	29
Gambar 3. 1 Diagram Alir.....	32
Gambar 4. 1 Plot Penutupan Saham Indosat	33
Gambar 4. 2 Plot Penutupan Saham Indosat setelah Normalisasi	36
Gambar 4. 3 Plot ACF dan PACF.....	36
Gambar 4. 4 Plot Penutupan Saham setelah <i>differencing</i>	37
Gambar 4. 5 Plot ACF dan PACF data Saham Indosat differencing.....	38
Gambar 4. 6 Perbandingan nilai prediksi dan actual 7 input, 20 hidden layer....	52
Gambar 4. 7 Hasil Peramalan Model GARCH (1,0).....	67
Gambar 4. 8 Hasil Peramalan Model Backpropagation	68

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Saham bisa didefinisikan sebagai sertifikat yang menampilkan fakta kepemilikan pada sesuatu industri serta pemilik saham mempunyai hak atas pemasukan serta peninggalan industri. Harga saham merupakan aspek yang sangat penting dicermati oleh investor. Harga saham nilainya berfluktuatif, sehingga penambahan nilai harga saham disebut juga pergerakan nilai harga saham dalam prakteknya harga saham dari setiap perusahaan di bursa efek dinyatakan dengan indeks harga saham. Jika nilai indeks harga saham naik artinya setiap indeks memiliki nilai sahamnya naik begitupun sebaliknya. Indeks harga saham merupakan ukuran yang mengukur perubahan harga dari pasar saham. Pergerakan indeks harga saham menjadi pedoman investor dalam memantau perkembangan pemasukan tanpa mengikuti naik turunnya tiap-tiap saham.

Penulis mengambil PT. Indosat, Tbk sebagai objek penelitian, dimana perusahaan tersebut berdiri pada tahun 1967 sebagai perusahaan yang menyediakan jasa komunikasi internasional di Indonesia dan perusahaan tersebut mengalami perkembangan yang sangat pesat terutama dari struktur finansialnya yang didukung oleh penerbitan saham. Pada saat ini PT. Indosat Tbk, merupakan perusahaan penyedia jasa komunikasi yang menduduki peringkat kedua sebagai operator selular di Indonesia. (profil PT. Indosat, Tbk, 2006) Pada kenyataannya harga saham PT. Indosat mengalami kenaikan dan penurunan saham (fluktuatif), hal tersebut mungkin berkaitan dengan besarnya nilai *return on asset*, besar laba ditahan dan rasio pembayaran dividennya.

Pergerakan harga saham memiliki fluktuatif sehingga informasi ini memiliki pergantian variansi yang tidak konstan. Salah satu metode yang cocok untuk meramalkan informasi saham yang berfluktuatif adalah model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), yang merupakan pengembangan dari model *Autoregressive Conditional Heteroscedasticity* (ARCH). Model ARCH pertama kali diperkenalkan oleh Engle pada tahun 1982. Model ini mampu menggambarkan semua karakteristik dari variabel-variabel pasar keuangan. Namun, pada permasalahan keuangan dengan tingkat volatilitas yang lebih besar, model ini memerlukan orde yang besar supaya didapatkan model

yang tepat. Untuk menghindarinya, Bollerslev (1986) mengembangkan model ARCH menjadi *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Menurut Ariefianto (2012), Hasanah, dkk (2019), Kingsley dan Peter (2019) dan Sharma dan Vipul (2015) model GARCH memiliki karakteristik respon volatilitas yang simetris nonlinear.

GARCH merupakan model nonlinear dari data runtun waktu (Donaldson dan Kamstra 1997), karena metode GARCH mampu menyelesaikan runtun waktu yang tak linear. Oleh karena itu, Tealab (2018) menyarankan model matematik nonlinear lainnya yaitu skema *Artificial Neural Network* (ANN).

Artificial Neural Network adalah paradigma pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia. Elemen kunci dari paradigma ini adalah struktur dari sistem pengolahan informasi yang terdiri dari sejumlah besar elemen pemrosesan yang saling berhubungan (*neuron*), bekerja serentak untuk menyelesaikan masalah tertentu. Cara kerja *Artificial Neural Network* seperti cara kerja manusia, yaitu belajar melalui contoh. *Artificial Neural Network* merupakan sistem prosesor paralel terhubung satu sama lain dalam bentuk grafik diarahkan. menurut bagan setiap neuron dari jaringan direpresentasikan sebagai node. koneksi ini memberikan struktur hirarkis yang mencoba untuk meniru fisiologi otak, mencari model-model baru pengolahan untuk memecahkan masalah tertentu di dunia nyata. Permasalahan penting dalam pengembangan teknik *Artificial Neural Network* adalah perilaku yang berguna harus dipelajari, diakui dan diterapkan antara obyek dan frame benda di dunia nyata (Freeman dkk., 1992). Lapisan-lapisan penyusun *Artificial Neural Network* dibagi menjadi 3, yaitu lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*) (Sutojo, 2010).

Salah satu metode *Artificial Neural Network* yang digunakan untuk peramalan harga saham adalah model *Backpropagation*, Rong dkk, (2005). Model ini digunakan karena dalam kebanyakan kasus mengenali pola diperlukan mengidentifikasi ketika fakta-fakta atau fenomena akan terjadi lagi sebelum terjadi. *Artificial Neural Network Backpropagation* memiliki satu lapisan tersembunyi (*hidden*), meskipun pada dasarnya dapat memiliki lebih dari satu lapisan tersembunyi sesuai dengan kebutuhan sistem. Sedangkan jumlah layer terhubung pada *hidden layer* dan lapisan keluaran ditentukan oleh jumlah pola *hidden layer* dan jumlah pola *output layer*. Pelatihan pada *Neural Network* adalah pelatihan untuk menentukan nilai bobot yang sesuai. Pelatihan pada *Artificial Neural*

Network Backpropagation terdiri dari tiga tahap yaitu; pelatihan umpan maju (*feedforward*), perhitungan mundur (*backforward*) dan penyesuaian bobot. Kelebihan Algoritma *Backpropagation* adalah dapat diaplikasikan pada penyelesaian suatu masalah berkaitan dengan identifikasi, prediksi, peramalan, pengenalan pola dan sebagainya (Dessy dan Irawan, 2012), kemampuannya untuk belajar (bersifat adaptif) dan kebal terhadap kesalahan (*Fault Tolerance*) sehingga dapat mewujudkan sistem yang tahan kerusakan (*robust*) dan bekerja secara konsisten (Dessy dan Irawan, 2012), melatih jaringan untuk mendapat keseimbangan selama proses pelatihan sehingga dapat memberikan respon yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan (Wanto, dkk, 2019).

Artificial Neural Network Backpropagation merupakan salah satu sistem pemrosesan informasi yang didesain dengan menirukan cara kerja otak manusia dalam menyelesaikan suatu masalah melalui proses belajar dengan perubahan bobot. *Artificial Neural Network Backpropagation* mengidentifikasi pola data dari harga saham dengan metode pendekatan pembelajaran atau pelatihan dan pengujian.

Dalam penelitian Azadeh, dkk. (2012) membandingkan dua metode antara *Artificial Neural Network* dan regresi *fuzzy* untuk memprediksi harga minyak, menyimpulkan bahwa model *Artificial Neural Network* memiliki nilai *mean absolute persentase error* (MAPE) terkecil. Penelitian yang dilakukan Ping, dkk. (2013) tentang peramalan harga emas di Malaysia menggunakan metode GARCH dan ARIMA, diperoleh hasil bahwa model GARCH memiliki nilai *error* terkecil dibandingkan dengan ARIMA. Penelitian yang dilakukan Sharma dan Vipul (2015) pada 21 index saham menggunakan model GARCH dibandingkan dengan EGARCH, TGARCH, MGARCH, hasil yang diperoleh GARCH adalah model yang terbaik dibandingkan dengan EGARCH, TGARCH dan MGARCH.

Pada tugas akhir ini dilakukan penelitian tentang perbandingan Metode *Artificial Neural Network Backpropagation* dan GARCH dalam memprediksi harga saham Indosat dari tahun 2012 sampai tahun 2022, jumlah data 2.453, akan dibagi dalam dua bagian yaitu data latih dan data uji, dimana 80% digunakan untuk data latih untuk membuat model sedangkan 20% data uji digunakan untuk mengukur keakuratan peramalan pada data saham Indosat.

1.2. Rumusan Masalah

Berdasarkan latar belakang penelitian, rumusan masalah yang akan dibahas pada penelitian ini adalah sebagai berikut:

1. Bagaimana pembentukan model *Artificial Neural Network Backpropagation* dan GARCH yang baik untuk meramalkan data harga saham?
2. Seberapa besar keakuratan peramalan harga saham yang dihasilkan oleh *Artificial Neural Network Backpropagation* jika dibandingkan dengan hasil peramalan dari GARCH?

1.3. Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, maka tujuan penulisan penelitian ini adalah sebagai berikut:

1. Mendapatkan model *Artificial Neural Network Backpropagation* dan GARCH untuk meramalkan data harga saham.
2. Memperoleh hasil peramalan data harga saham menggunakan model GARCH dan *Artificial Neural Network Backpropagation*.

1.4. Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Hasil peramalan harga saham yang diperoleh dapat menjadi wacana dalam mengindikasikan kondisi pasar saham pada periode selanjutnya.
2. Menambah wawasan dan pengetahuan mengenai jenis teknik peramalan indeks saham dan langkah-langkah yang digunakan.
3. Bagi para investor diharapkan penelitian ini dapat menjadi bahan pertimbangan untuk melakukan analisis investasi pada saham Indosat.

1.5. Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah:

1. Data harga saham yang digunakan adalah harga penutupan saham Indosat pada tanggal 06 Maret 2012 - 18 Januari 2022.
2. Metode yang digunakan *Artificial Neural Network Backpropagation* dan *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)*.

BAB II

TINJAUAN PUSTAKA

2.1. Deret Waktu (*Times Series*)

Time series adalah pengamatan pada suatu variabel dari waktu lampau dan dicatat secara berurutan menurut urutan waktu dengan periode yang tetap (Hanke & 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. Beberapa konsep dasar dalam analisis *time series* adalah autokorelasi, konsep *white noise* dan plot data. *Times series* dapat muncul dalam berbagai pola seperti stasioner, tidak stasioner, pola musiman, maupun pola tidak musiman. Menganalisis *times series* bertujuan untuk memperoleh model yang sesuai dengan deret waktu yang diamati untuk selanjutnya digunakan sebagai model peramalan deret waktu yang akan datang (Makridakis, 1995).

Deret waktu adalah serangkaian data pengamatan yang disusun menurut urutan waktu, pengamatan yang dilakukan harus dalam unit selang waktu yang sama (Cryer, 1986). Menurut Box dan Jenkins (1976) deret waktu adalah sekelompok nilai-nilai pengamatan yang diperoleh pada titik waktu yang berbeda dengan selang waktu yang sama dan barisan data diasumsikan saling berhubungan satu sama lain, jadi model deret waktu adalah suatu model runtun waktu di mana observasi yang satu dengan yang lain saling berkorelasi. Model *time series* dapat dibagi menjadi dua berdasarkan variabel yang diamati. Deret waktu univariat adalah analisis *time series* yang hanya mengamati satu variabel atau individu runtun waktu (*time series*). Identifikasi untuk data univariate *time series* dapat dilihat dengan pola *Autocorrelation Function* (AFC) dan *Partial Autocorrelation Function* (PACF).

2.2. Deret Waktu Univariat

2.2.1. Stasioner

Deret waktu dikatakan stasioner jika tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi. Pendeteksian kestasioneran dalam

variansi dapat dilakukan dengan melihat plot Box-Cox data (Box & Cox, 1964). Sedangkan untuk memeriksa kestasioneran dalam rata-rata, dapat digunakan diagram deret waktu (*time series plot*) yaitu diagram pencar antara nilai variabel Z_t dengan waktu t . Jika diagram deret waktu berfluktuasi di sekitar garis yang sejajar sumbu waktu (t) maka dikatakan deret (*series*) stasioner dalam rata-rata (Aswi, 2006).

Selain cara tersebut, pendeteksian stasioner dalam rata-rata dapat dilakukan dengan uji *Augmented Dickey Fuller* (ADF). Uji ADF merupakan salah satu pengujian statistik yang digunakan untuk menguji kestasioneran data dalam rata-rata, yang berguna untuk mengakomodasi terjadinya korelasi pada residual dengan menambahkan lag-lag dari variabel dependen Z_t . Secara spesifik, uji ADF mengikuti estimasi regresi berikut (Gujarati, 2003):

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \sum_{i=1}^p \alpha_i \Delta Z_{t-i} + \varepsilon_t \quad (2.1)$$

Keterangan:

β_1 : konstanta

β_2 : koefisien pada tren waktu

δ : koefisien variable pada periode $t - 1$

α_i : koefisien dari *autoregressive*

ε_t : sisaan yang bersifat acak

Uji ADF memiliki hipotesis sebagai berikut:

$H_0 : \delta = 0$ (data tidak stasioner)

$H_1 : \delta \neq 0$ (data stasioner)

Statistik uji:

$$t_{hit} = \frac{\hat{\delta}}{SE \hat{\delta}}$$

Daerah penolakan

Tolak H_0 jika $|t_{hit}| > t_{tabel}$ atau $p_{value} < \alpha$, yang menunjukkan bahwa data telah stasioner dalam rata-rata.

Bila kondisi stasioner dalam rata-rata tidak terpenuhi diperlukan proses pembedaan (*differencing*) (Aswi, 2006). Proses *differencing* pada orde pertama merupakan selisih antara data ke- t dengan data ke $t - 1$, yaitu:

$$\Delta Z_t = Z_t - Z_{t-1}$$

2.2.2. Autocorrelation Function (ACF)

Autocorrelation Function merupakan suatu alat penentu dari identifikasi pola dasar yang menggambarkan data. Menurut Arsyad (1994) autokorelasi dapat digunakan untuk mengidentifikasi apakah data bersifat acak, stasioner ataupun musiman. Fungsi autokorelasi dilambangkan dengan ρ_k yang merupakan tingkat keeratan hubungan antara z_t dan z_{t-k} dari proses yang sama dan hanya dipisahkan oleh selang waktu ke- k . Koefisien autokorelasi merupakan korelasi deret waktu itu sendiri dengan lag $k = 0, 1, 2$ atau lebih (Makridakis, Wheelwright dan McGee, 1999). Cryer dan Chan (2008) menjelaskan bahwa koefisien fungsi autokorelasi ρ_k dapat diduga dengan:

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

Keterangan:

r_k : koefisien korelasi pada lag k

Z_t : data pengamatan pada waktu ke- t

Z : rata-rata data pengamatan

2.2.3. Partial Autocorrelation Function (PACF)

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan hubungan linier antara data Z_t dan Z_{t-k} apabila pengaruh dari lag $1, 2, \dots, k-1$ dianggap terpisah (Makridakis dkk., 1999). Menurut Cryer (1986), taksiran dari PACF diperoleh berdasarkan koefisien autokorelasi pada persamaan *Yule-Walker* untuk lag ke- k , yaitu:

$$\begin{aligned} \rho_1 &= \phi_{k1} + \rho_1 \phi_{k2} + \rho_2 \phi_{k3} + \dots + \rho_{k-1} \phi_{kk} \\ \rho_2 &= \rho_1 \phi_{k1} + \phi_{k2} + \rho_1 \phi_{k3} + \dots + \rho_{k-2} \phi_{kk} \\ &\vdots \\ \rho_k &= \rho_{k-1} \phi_{k1} + \rho_{k-2} \phi_{k2} + \rho_{k-1} \phi_{k3} + \dots + \phi_{kk} \end{aligned} \quad (2.3)$$

Persamaan (2.2) dapat diselesaikan untuk pendugaan nilai PACF, yaitu sebagai berikut:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \quad (2.4)$$

Keterangan

ϕ_{kk} : koefisien autokorelasi parsial pada lag k

ρ_k : koefisien autokorelasi pada lag k yang diduga dengan r_k

2.2.4. ARIMA

Afeef et al (2018) melakukan penelitian untuk menentukan model ARIMA apakah lebih cocok untuk memprediksi harga saham jangka pendek atau jangka panjang. Penelitian ini menemukan bahwa ARIMA memiliki kapasitas yang sangat baik untuk memperkirakan nilai masa depan saham dalam jangka pendek. Temuan yang serupa juga di peroleh dari penelitian yang dilakukan oleh Gaspareniene et al. (2018) yang melakukan penelitian harga emas dari Januari 1968 sampai dengan Desember 2015 mereka menemukan bahwa model ARIMA dapat memprediksi tren harga emas dimasa depan, namun ARIMA hanya cocok untuk memprediksi harga emas dalam jangka pendek dan hanya cocok untuk data yang tidak begitu fluktuasi.

Tri (2017) juga menggunakan ARIMA model untuk memprediksi harga saham di Indonesia dari Januari tahun 2010 sampai dengan Desember 2014. Hasil dari penelitian ini menunjukkan bahwa model ARIMA yang paling cocok adalah ARIMA (0,1,1) dengan nilai *akaike information criterion* (AIC) paling terkecil. *forecasting* harga saham menggunakan ARIMA (0,1,1) menunjukkan tingkat akurasi model ARIMA sebesar 84,31% yang berarti ARIMA sangat cocok dalam memprediksi saham di Indonesia.

Hasil dari penelitian yang dilakukan oleh Susruth (2017) menunjukkan bahwa model ARIMA merupakan model *forecasting* yang terbaik dalam melakukan *forecasting* pada harga saham S&P 500 Index dan NIFTY 500 Index. Nilai MAPE untuk metode *forecasting* ARIMA 4,32% sedangkan model *forecasting moving average* 95,44% dan model *forecasting Holt and Winter* 9,14%. Berdasarkan penelitian Modal et al. (2014) yang melakukan penelitian *forecasting* dengan menggunakan ARIMA model pada 59 harga saham dari 7 sektor yang berbeda-beda, model ARIMA (1,0,2) dapat memprediksi dengan tingkat akurasi 95,93% pada sektor *Fast Moving Consumer Goods (FMCG)*.

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan hasil penggabungan antara model *autoregressive* AR (p), *moving average* MA (q) dengan proses *differencing* (d). Model *autoregressive* adalah suatu bentuk regresi, tetapi tidak menghubungkan variabel tak bebas melainkan menghubungkan nilai-nilai sebelumnya pada selang waktu (*time lag*) yang bermacam-macam. Jadi, suatu model *autoregressive* akan menyatakan suatu ramalan sebagai fungsi nilai-nilai sebelumnya dari deret waktu tertentu (Makridakis, Wheelwright, & Hyndman,

1998). Sedangkan model *moving average* merupakan model yang menggambarkan ketergantungan variabel terikat Z terhadap nilai-nilai residual pada waktu sebelumnya yang berurutan.

Secara umum, bentuk model ARIMA (p,d,q) sebagai berikut:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)e_t \quad (2.5)$$

Keterangan:

p : orde AR

q : orde MA

d : orde *differencing*

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$$

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p)$$

$\phi_1, \phi_2, \dots, \phi_p$: koefisien orde p

$\theta_1, \theta_2, \dots, \theta_p$: koefisien orde q

Z_t = pengamatan pada waktu ke- t

2.2.5. Ukuran Ketepatan Peramalan

Untuk mengevaluasi efisiensi perkiraan, penelitian ini menggunakan ukuran statistic *mean absolute percentage error* (MAPE) dan *Mean Square Error* (MSE). MAPE adalah nilai *absolute* dari persentase *error* data terhadap *mean*. Pendekatan MAPE digunakan untuk mengevaluasi ketepatan dari suatu ramalan, MAPE dapat mengindikasikan kesalahan dalam meramal yang dibandingkan dengan nilai nyata. Rumus dari MAPE dituliskan sebagai berikut (Ping, 2013):

$$MSE = \left(\frac{\sum_{t=1}^n (\bar{y} - y_t)}{n} \right)^2 \quad (2.6)$$

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

Keterangan:

y_t : data aktual

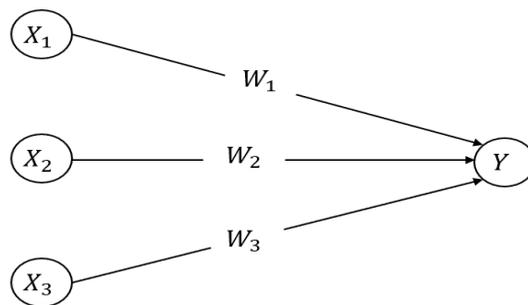
\bar{y} : data peramalan

n : jumlah data

Semakin kecil nilai MAPE maka nilai taksiran semakin mendekati dengan nilai yang sebenarnya atau dengan kata lain metode yang dipilih merupakan metode yang terbaik. Sebuah metode mempunyai kinerja sangat bagus apabila nilai MAPE berada di bawah 10% dan mempunyai kinerja bagus jika nilai berada di antara 10% dan 20% (Pusparinda, 2017).

2.3. Artificial Neural Network (ANN)

Menurut Puspitaningrum (2006) model *Artificial Neural Network* ditentukan oleh 2 hal yaitu arsitektur jaringan dan algoritma pelatihan. Tugas arsitektur yaitu untuk memperjelas arah perjalanan yang ada dalam sebuah jaringan, Sedangkan algoritma pelatihan berfungsi untuk melatih bobot koneksi dan harus diubah jika diperlukan supaya target keluaran tercapai. Terdapat berbagai cara untuk melakukan suatu perubahan nilai bobot, tergantung jenis algoritma pelatihan yang dipakai. Perubahan bobot ini dilakukan supaya kerja jaringan dalam hal mempelajari banyak pola akan menghasilkan target keluaran yang meningkat, sebagai contoh pada gambar 2.1.



Gambar 2. 1 ANN dengan pembobot

dengan

X_1, X_2, X_3 : nilai input

W_1, W_2, W_3 : bobot

Y : output

Gambar 2.1 merupakan contoh gambar *artificial neural network* dengan simpul Y menerima masukan X_1, X_2, X_3 dengan nilai bobot masing-masing W_1, W_2, W_3 . Lalu ketiga sinyal simpul tersebut dijumlahkan $net = X_1W_1 + X_2W_2 + X_3W_3$. Besarnya sinyal yang diterima oleh Y tergantung fungsi aktivasinya $y = (net)$. Untuk melakukan perubahan bobot digunakan nilai fungsi aktivas.

$$y_{net} = X_1W_1 + X_2W_2 + X_3W_3 \quad (2.8)$$

2.4. Konsep Dasar Artificial Neural Network

Setiap pola-pola informasi *input* dan *output* yang diberikan kedalam *Artificial Neural Network* diproses dalam neuron. Neuron-neuron tersebut terkumpul didalam lapisan-lapisan yang disebut neuron layers. Lapisan-lapisan penyusun jaringan saraf tiruan tersebut dapat dibagi menjadi 3 (Puspitaningrum, 2006), yaitu:

a. Lapisan Masukan (*input layer*)

Unit-unit didalam lapisan input disebut unit-unit input. Unit-unit input tersebut menerima pola inputan data dari luar yang menggambarkan suatu permasalahan.

b. Lapisan Tersembunyi (*hidden layer*)

Unit-unit didalam lapisan tersembunyi disebut unit-unit tersembunyi. Dimana outputnya tidak dapat secara langsung diamati.

c. Lapisan Keluaran (*output layer*)

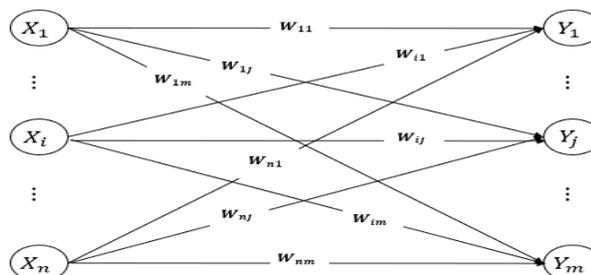
Nilai keluaran dari hasil perhitungan keseluruhan

2.5. Arsitektur Artificial Neural Network

Artificial Neural Network memiliki jaringan yang sering digunakan dalam berbagai aplikasi (Puspitaningrum, 2006). Arsitektur *Artificial Neural Network* tersebut, antara lain:

1. Jaringan Layer Tunggal

Jaringan dengan lapisan tunggal yang terdiri dari 1 layer input dan 1 layer output. Setiap neuron yang terdapat didalam lapisan input selalu terhubung dengan setian neuron yang terdapat pada layer output. Jaringan ini hanya menerima input kemudian secara langsung akan mengolahnya menjadi output tanpa harus melalui lapisan tersembunyi.



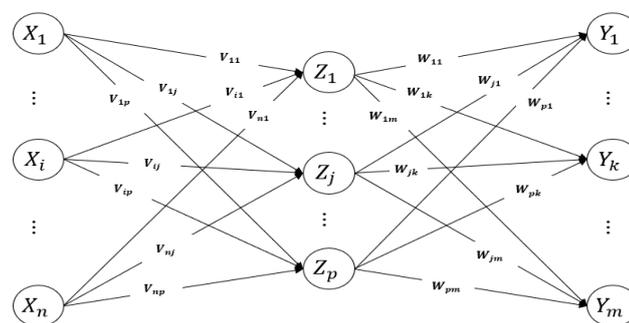
Gambar 2. 2 Jaringan Layer Tunggal

Keterangan :

- X_i : nilai *input*, ($i = 1, \dots, n$)
 Y_i : nilai *output*
 W_{nm} : bobot

2. Jaringan Layer Jamak

Dalam jaringan *multilayer*, selain ada unit-unit *input* dan unit-unit *output*, juga terdapat unit-unit tersembunyi (*hidden*). Jumlah unit *hidden* tergantung pada kebutuhan. Semakin kompleks jaringan, unit *hidden* yang dibutuhkan makin banyak, demikian pula jumlah *layernya*. Arsitektur jaringan layer jamak ditunjukkan pada gambar berikut :



Gambar 2. 3 Jaringan Layer Jamak

Keterangan :

- Z : nilai *hidden layer*
 V_i : bobot

2.6. Backpropagation

Penelitian yang dilakukan oleh Ilyas, N., dkk (2022) tentang analisis sirkulasi dan peramalan penjualan bahan bakar menggunakan metode *backpropagation artificial neural network*, penelitian terhadap premium dan pertalite di SPBU Hasanuddin Makassar dari tanggal 1 Januari 2018 – 29 Maret 2021 dengan banyaknya data 1121 data. Hasil yang diperoleh untuk pertalite dengan 4 input layer dan 5 neuron pada lapisan tersembunyi memiliki akurasi terbaik dengan MAPE sebesar 17.64% sedangkan untuk pertalite dengan 7 input layer dan 25 neuron pada lapisan tersembunyi memiliki akurasi MAPE sebesar 14.64%.

Penelitian yang dilakukan oleh Meizer dan Brady Rikumahu (2019) tentang Prediksi Nilai Saham Pertanian dan Pertambangan yang terdaftar di indeks kompas 100 menggunakan *artificial neural network backpropagation*, hasil penelitian dengan beberapa variasi percobaan menggunakan nilai *hidden layer* yang bervariasi. 10, 20, 30 dengan variasi nilai turunan gradien : 0.01, 0.001 dan

0.0001 serta variasi nilai epoch 100, 200 dan 300, menghasilkan model prediksi jaringan yang memberikan pelatihan dengan tingkat kesalahan minimum berada pada *output layer 5*, *hidden layer 20* dan *output layer 1* dengan nilai turunan gradien 0.01 dan epoch 300.

Penelitian yang dilakukan H. Khanna Nehemia dan A. Kannan, (2016) dengan judul Optimalisasi pengklasifikasi jaringan saraf menggunakan evolusi diferensial dengan informasi global dan *algorithm backpropagation* untuk kumpulan data klinis menerangkan bahwa kinerja pengklasifikasi jaringan saraf terlatih dibandingkan dengan *backpropagation gradient descent*. Hasil yang diperoleh dalam penelitian ini adalah *backpropagation gradient descent* memberikan akurasi 85.71 persen untuk diabetes, 98.52 persen untuk kanker payudara dan 86.66 persen untuk penyakit jantung. Penelitian yang dilakukan oleh Sneha Joshi, 2016 tentang deteksi dan prediksi diabetes melitus menggunakan *artificial neural network backpropagation* diperbantukan dengan MATLAB menunjukkan bahwa implementasi dan pengembangan *artificial neural network backpropagation* yang digunakan untuk memprediksi diabetes melitus dengan akurasi 81 persen.

Penelitian yang dilakukan oleh Wisnu Hendro Martono, Dian Hartanti (2015) dengan judul penelitian "Penggunaan Jaringan Syaraf Tiruan Dengan Metode Backpropagation Dalam Memprediksi Indeks Harga Saham Gabungan (IHSG)". Data yang digunakan pada penelitian ini adalah 7 perusahaan yaitu PT. Astra International Indonesia, PT. HM Sampurna, PT. Unilever Indonesia, PT. Telkom Indonesia, PT. United Tractor, PT. Gudang Garam, dan PT Perusahaan Gas Negara. Hasil yang diperoleh pada penelitian ini adalah nilai MSE yang didapatkan adalah 3,636604 setelah bobot dan bias dioptimasi pada saat pelatihan dengan iterasi sebanyak 50 kali dihasilkan nilai MSE sebesar 0,0922114. Pada saat bobot dan bias yang telah dioptimasi digunakan pada jaringan syaraf tiruan untuk meramalkan nilai IHSG pada periode mendatang, nilai MSE yang didapatkan adalah 0,0348015.

Siti Amiroch (2015) dengan judul penelitian "Prediksi Harga Saham Menggunakan Jaringan Syaraf Tiruan *Backpropagation*" dalam penelitiannya dilakukan prediksi menggunakan jaringan syaraf tiruan dalam bidang petroleum, chemical, logistik, pabrikan dan batubara yaitu memprediksi harga saham penutupan (*Close*) pada PT AKR Corporindo Tbk (AKRA Corporindo). Data yang digunakan dalam penelitian ini sebanyak 120 data, data *training* sebanyak 24 data, dan *testing* sebanyak 5 data. Dari hasil penelitian data saham AKRA diperoleh

hasil prediksi saham yang mendekati harga sesungguhnya dengan nilai MSE yang sangat kecil dan hasil *training* yang sangat bagus.

Penelitian yang dilakukan oleh (Nur'afifah, 2011) dengan judul penelitian “Analisis Metode *Backpropagation* Untuk Memprediksi Indeks Harga Saham Pada Kelompok Indeks Bisnis-27”. Dalam penelitian tersebut untuk mengetahui pola-pola pada indikator teknikal yang mempengaruhi penurunan atau kenaikan indeks saham, dengan melihat data-data saham sebelumnya. Data yang digunakan dalam penelitiannya dari periode Januari 2009 sampai dengan Desember 2010, dengan data pelatihan sebanyak 369 dan data pengujian sebanyak 100 data. Hasil yang diperoleh dari penelitian ini adalah peramalan harga saham untuk hari berikutnya (1 Januari 2011) adalah 332.20 lebih rendah dari harga sebeumnya 20 Desember 2010 yaitu 322.29 dengan selisih 0.09, dengan nilai *Mean square error* (MSE) sebesar 0.00476 pada iterasi ke 20848.

Penelitian yang dilakukan oleh Ita Qorry Aina (2018) dengan judul penelitian “Implementasi *Artificial Neural Network* (ANN) Dengan Algoritma *Backpropagation* untuk Memprediksi Volume Penjualan Di Bukalapak” dalam penelitian menggunakan studi kasus dari aksesoris komputer di marketplace Bukalapak. Diperoleh 3 jenis kategori aksesoris computer yang dianalisis yaitu *mouse*, *speaker & sound*, dan tas & case. Data yang diperoleh dengan cara *scraping* yang dilakukan dari tanggal 10 Februari 2018 hingga 13 Februari 2018. Hasil rancangan arsitektur yang diperoleh yaitu 3 layer yang meliputi 7 neuron *input layer*, 3 neuron pada *hidden layer*, dan 1 neuron pada *output layer*. Tingkat akurasi yang dihasilkan dalam penelitian ini adalah sebesar 98.99%.

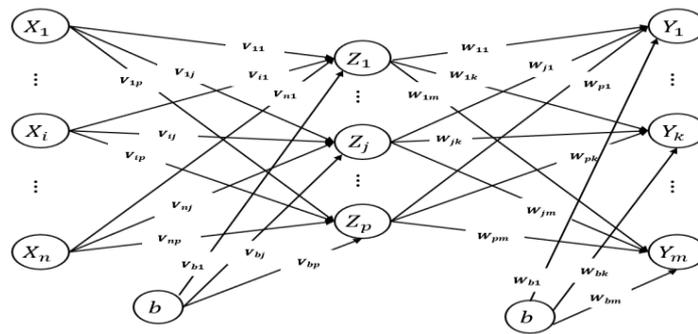
Penelitian yang dilakukan oleh (Supriyadi, 2018). Dengan judul “Analisis Klasifikasi Genre Musik Pop dan Klasik pada Layanan Streaming Musik Spotify Menggunakan *Artificia Nueural Network* (ANN)” Dalam penelitiannya data *input* yang digunakan adalah *acousticness*, *danceability*, *energy*, *loudness*, *speechiness*, *tempo* dan *valence* kemudian *output* nya adalah genre music pop dan klasik. Arsitektur jaringan yang diperoleh pada penelitian ini adalah 7 neuron input, 1 *hidden layer* dengan 4 neuron dan 1 *output*. Hasil dari nilai akurasi pada penelitian ini dari pengujian diperoleh sebesar 99.5%

Backpropagation merupakan salah satu algoritma pembelajaran dalam *artificial neural network* (Amrin, 2016). Proses pembelajaran *backpropagation* dilakukan dengan penyesuaian bobot-bobot jaringan *artificial neural* dengan arah mundur berdasarkan nilai *error* dalam proses pembelajaran (Windarto, Lubis dan

Solikhun, 2018). Ciri khas *backpropagation* melibatkan tiga lapisan (*layer*) utama : lapisan masukan (*input layer*) berfungsi sebagai penghubung jaringan ke sumber data, lapisan tersembunyi (*hidden layer*) di mana jaringan dapat memiliki lebih dari satu *hidden layer*, Lapisan luaran (*output layer*) di mana hasil dari masukan yang diberikan oleh *input layer* (Wanto dan Windarto, 2017) dengan menggunakan fungsi *Sigmoid* (Khairani, 2014). Keluaran dari pada lapisan ini sudah dianggap sebagai hasil dari proses.

Tujuan utama pemakaian *Backpropagation* untuk memperoleh penyeimbang antara pengenalan pola pelatihan secara benar serta reaksi yang baik buat pola lain yang sejenis (data pengujian). Jaringan bisa dilatih terus menerus sampai seluruh pola pelatihan dikenali dengan benar. Hendak namun perihal itu tidak menjamin jaringan hendak sanggup mengidentifikasi pola pengujian dengan pas. Jadi bukanlah berguna buat meneruskan iterasi sampai seluruh kesalahan pola pelatihan = 0. Pada *backpropagation* biasanya informasi dipecah jadi 2 bagian silih asing, ialah pola informasi yang digunakan selaku pelatihan serta informasi yang dipakai buat pengujian (Fauset, L. 1994). Sebagian komposisi data pelatihan dan pengujian yang sering digunakan adalah sebagai berikut (Adya, M. & Collopy, F.1998), 80% data pelatihan dan 20% data pengujian, 70% data pelatihan dan 30% data pengujian, $\frac{2}{3}$ untuk data pelatihan dan $\frac{1}{3}$ untuk data pengujian, 50% untuk data pelatihan dan 50% untuk data pengujian.

Backpropagation memiliki beberapa unit neuron yang ada dalam satu atau lebih layer tersembunyi. Arsitektur *backpropagation* dengan n buah masukan (ditambah sebuah bias), sebuah layer tersembunyi yang terdiri dari p unit (ditambah sebuah bias), serta m buah unit keluaran. v_{ij} merupakan bobot garis dari unit masukan x_i ke unit *hidden layer* z_j (v_{0j} merupakan bobot garis yang menghubungkan bias di unit masukan ke unit layer tersembunyi z_j). w_{jk} merupakan bobot dari unit layer tersembunyi z_j ke unit keluaran y_k (w_{0k} merupakan bias di layer tersembunyi ke unit keluaran z_k) (Fauset,L. 1994).



Gambar 2. 4 Jaringan Backpropagation

Keterangan :

- X_i : nilai *input* ($i = 1, \dots, n$)
- Z_j : nilai *hidden layer* ($j = 1, \dots, p$)
- Y_k : nilai *output* ($k = 1, \dots, m$)
- W_i : bobot antara *hidden layer* ke *output*
- V_i : bobot antara *input layer* ke *hidden layer*
- b : bias

Pelatihan *backpropagation* meliputi 3 fase. Fase awal merupakan fase maju. Pola masukan dihitung maju mulai dari layer masukan sampai layer keluaran dengan fungsi aktivasi yang ditentukan. Fase kedua merupakan fase mundur. Selisih antara keluaran dengan target yang diinginkan ialah kesalahan yang terjadi. Kesalahan tersebut di *backpropagation*, diawali dari garis yang berhubungan langsung dengan unit-unit di layer keluaran. Fase ketiga merupakan modifikasi bobot buat meminimalkan kesalahan yang terjalin (Fauset,L. 1994).

Fase I: *Forward Propagation*

Selama propagasi maju, sinyal masukan (x_i) dipropagasikan ke *hidden layer* menggunakan fungsi aktivasi yang ditentukan. Keluaran dari setiap unit layer tersembunyi (z_j) tersebut selanjutnya dipropagasikan maju lagi ke *hidden layer* di atasnya menggunakan fungsi aktivasi yang ditentukan. Demikian seterusnya hingga menghasilkan keluaran jaringan (y_k).

Selanjutnya, keluaran jaringan (y_k) dibandingkan dengan target yang harus dicapai (t_k). Selisih $t_k - y_k$ adalah kesalahan yang terjadi. Jika kesalahan ini lebih kecil dari batas toleransi yang ditentukan, maka iterasi dihentikan. Akan tetapi apabila kesalahan masih lebih besar dari batas toleransinya, maka bobot setiap garis dalam jaringan akan dimodifikasi untuk mengurangi kesalahan yang terjadi.

Fase II: *Backpropagation*

Berdasarkan kesalahan $t_k - y_k$, dihitung aspek δ_k ($k = 1, 2, \dots, m$) yang dipakai untuk mendistribusikan kesalahan di unit y_k ke semua unit tersembunyi yang terhubung langsung dengan y_k . δ_k juga dipakai untuk mengubah bobot garis yang berhubungan langsung dengan unit keluaran. Dengan cara yang sama, dihitung faktor δ_j di setiap unit di layer tersembunyi sebagai dasar perubahan bobot semua garis yang berasal dari unit tersembunyi di layer di bawahnya. Demikian seterusnya hingga semua faktor δ di unit tersembunyi yang berhubungan langsung dengan unit masukan dihitung.

Fase III: Perubahan bobot

Setelah semua faktor δ dihitung, bobot semua garis dimodifikasi bersamaan. Perubahan bobot suatu garis didasarkan atas faktor δ neuron di layer atasnya. Sebagai contoh, perubahan bobot garis yang menuju ke layer keluaran didasarkan atas δ_k yang ada di unit keluaran.

Bentuk umum output dari backpropagation adalah sebagai berikut (Fausett, 1994:292)

$$y_k = w_{0k} + \sum_{j=1}^p w_{jk} \left(v_{0j} + \sum_{i=1}^n x_i v_{ij} \right) \quad (2.9)$$

$$y_k = w_{0k} + \sum_{j=1}^p w_{jk} (Z_net_j)$$

Dengan menggunakan fungsi aktivasi sigmoid dari $f(Z_net_j)$ didapatkan model output adalah sebagai berikut:

$$y_k = w_{0k} + \sum_{j=1}^p w_{jk} \left(\frac{1}{1 + e^{-v_{0j} + \sum_{i=1}^n x_i v_{ij}}} \right) \quad (2.10)$$

Keterangan:

- y_k : nilai *output*
- w_{0k} : bias pada *output layer*
- w_{jk} : bobot *hidden layer* ke *output*
- v_{ij} : bobot *input layer* ke *hidden layer*
- x_i : nilai *input*
- v_{0j} : bias pada *hidden layer*

Pada *hidden layer* kesalahan pada *output* unit didefinisikan

$$\varepsilon = \frac{1}{2} \sum_{k=1}^m (t_k - y_k)^2 \quad (2.11)$$

Keterangan:

ε : kesalahan pada unit keluaran/*error*

t_k : nilai target data

y_k : nilai *output*/keluaran actual

Algoritma pelatihan untuk jaringan dengan satu *layer* tersembunyi (dengan fungsi aktivasi sigmoid biner) adalah sebagai berikut (Fauset, L. 1994):

Langkah 0: Inisialisasi semua bobot dengan bilangan acak kecil

Langkah 1: Jika kondisi penghentian belum terpenuhi, lakukan langkah 2–9

Langkah 2: Untuk setiap pasang data pelatihan, lakukan langkah 3 – 8

Fase I: Propagasi maju

Langkah 3: Tiap unit input (X_i , $i = 1, 2, \dots, n$) menerima sinyal dan meneruskannya ke unit tersembunyi

Langkah 4: Hitung semua keluaran di unit tersembunyi Z_j ($j = 1, 2, \dots, p$)

$$Z_{net_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.12)$$

$$Z_j = f(Z_{net_j}) = \frac{1}{1 + e^{-Z_{net_j}}} \quad (2.13)$$

Keterangan :

Z_{net_j} : nilai untuk menghitung *hidden layer*

v_{0j} : bias antara input layer dengan *hidden layer*

x_i : nilai input *layer* ke- i ; ($i = 1, 2, \dots, n$)

v_{ij} : bobot antara *input layer* dan *hidden layer*

Z_j : nilai *hidden layer*

Langkah 5: Hitung semua keluaran jaringan di unit y_k ($k = 1, 2, 3, \dots, m$)

$$y_{net_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (2.14)$$

Fungsi aktivasi untuk menghitung sinyal *output*

$$y_k = f(y_{net_k}) = \frac{1}{1 + e^{-y_{net_k}}} \quad (2.15)$$

Keterangan:

y_{net_k} : masukan untuk unit y_k

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

w_{jk} : bobot *hidden layer* ke *output*

z_j : nilai aktivasi z_j (*output layer*)

y_k : nilai *output*

Fase II: *backpropagation*

Langkah 6: Hitung faktor δ unit keluaran berdasarkan kesalahan di setiap unit

keluaran y_k ($k = 1, 2, \dots, m$)

$$\delta_k = (t_k - y_k)f'(y_{net_k}) = (t_k - y_k)y_k(1 - y_k) \quad (2.16)$$

Keterangan :

δ_k : nilai aktivasi kesalahan pada *output layer*

t_k : nilai target data

δ_k merupakan unit kesalahan yang akan dipakai dalam perubahan bobot di bawahnya (langkah 7)

Hitung suku perubahan bobot w_{jk} (yang akan dipakai nanti untuk merubah bobot w_{jk}) dengan laju percepatan α .

$$\Delta w_{jk} = \alpha \delta_k z_j ; \quad k = 1, 2, \dots, m ; \quad j = 0, 1, \dots, p \quad (2.17)$$

Menghitung perubahan bias

$$\Delta w_{0k} = \alpha \delta_k \quad (2.18)$$

Keterangan :

Δw_{jk} : selisih antara $w_{jk}(t)$ dengan $w_{jk}(t + 1)$

Δw_{0k} : korelasi nilai bias

α : nilai *learning rate*, dimana $0 < \alpha < 1$.

z_j : nilai aktivasi dari unit z_j

Pelatihan jaringan pada *Artificial Neural Network Backpropagation*, dimana diambil nilai *learning rate* (α) dilakukan dengan simulasi terhadap beberapa nilai dengan melihat nilai *error* terkecil. Pada penelitian ini dilakukan simulasi terhadap *learning rate* (0.09, 0.1, 0.2, dan 0.3), diperoleh *error* MSE terkecil terdapat pada *learning rate* 0.1.

Langkah 7: Hitung faktor δ unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi z_j ($j = 1, 2, \dots, p$)

$$\delta_{net_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.19)$$

δ unit tersembunyi:

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} z_j(1 - z_j) \quad (2.20)$$

Keterangan:

δ_{net_j} : nilai untuk menghitung kesalahan *hidden layer*

w_{jk} : bobot dari z_j ke *output* y_k

δ_j : nilai aktivasi kesalahan pada *hidden layer*

Hitung suku perubahan bobot v_{ij} (yang akan dipakai nanti untuk merubah bobot v_{ij})

$$\Delta V_{ij} = \alpha \delta_j x_i \quad (2.21)$$

Menghitung perubahan bias

$$\Delta V_{0j} = \alpha \delta_j \quad (2.22)$$

Keterangan :

ΔV_{ij} : selisih antara $V_{ij}(t)$ dengan $V_{ij}(t + 1)$

ΔV_{0j} : korelasi nilai bias

x_i : unit ke i pada *input layer*

Fase III: Perubahan Bobot

Langkah 8: Hitung semua perubahan bobot

Perubahan bobot *Hidden layer* ke *output*

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}; \quad (k = 1, 2, \dots, m; \quad i = 0, 1, \dots, p) \quad (2.23)$$

Langkah 9 menghitung bobot dan bias baru

Perubahan bobot input ke *hidden layer*.

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij}; \quad (j = 1, 2, \dots, p; \quad i = 0, 1, \dots, n) \quad (2.24)$$

2.7. Fungsi Aktivasi

Penelitian yang dilakukan oleh Ilyas, N., dkk (2022), Sharma dan Vipul (2015) fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid biner. Fungsi aktivasi pada *Artificial Neural Network Backpropagation* digunakan untuk memformulasikan *output* dari setiap neuron. Pada *Artificial Neural Network* yang sering digunakan adalah fungsi aktivasi sigmoid biner. Hal yang penting dari fungsi ini adalah sebesar apapun nilai x (positif atau negatif) *output* dari fungsi ini tidak pernah mencapai 0.0 atau 1.0. Hasil dari fungsi ini bernilai antara 1 dan 0 (Siang, 2009).

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.25)$$

Keterangan:

e : bilangan euler 2,71828

x : hasil penjumlahan dari sinyal *input*

y : fungsi untuk mengaktifkan nilai x

y' : turunan dari $f(x)$

Untuk menjabarkan fungsi sigmoid biner diperlukan aturan hasil bagi

$$\text{Misalkan } g = 1, \quad g' = 0; \quad h = 1 + e^{-x}, \quad h' = -e^{-x}$$

$$f'(x) = \frac{g'(x)h(x) - g(x)h'(x)}{[h(x)]^2}$$

$$f'(x) = \frac{(0)(1 + e^{-x}) - (1)(-e^{-x})}{(1 + e^{-x})^2}$$

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

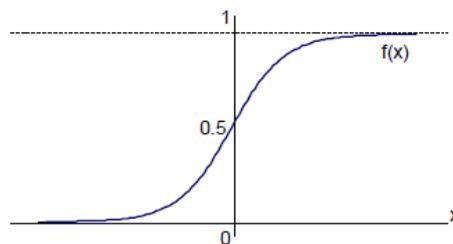
$$f'(x) = \frac{1 - 1 + e^{-x}}{(1 + e^{-x})^2}$$

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

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

$$f'(x) = \frac{1}{(1 + e^{-x})} - \left(1 - \frac{1}{1 + e^{-x}}\right)$$

$$f'(x) = f(x) (1 - f(x)) \quad (2.26)$$



Gambar 2. 5 Fungsi Sigmoid Biner

Fungsi sigmoid biner memiliki nilai maksimum < 1 . Maka untuk pola yang targetnya > 1 , pola masukan dan keluaran harus terlebih dahulu ditransformasi atau dinormalisasi sehingga semua polanya memiliki *range* yang sama seperti fungsi sigmoid biner.

Pada proses peramalan menggunakan *Artificial Neural Network Backpropagation*, sebelum dilakukan pelatihan data *input* dan target *output* harus ditransformasi terlebih dahulu. Transformasi adalah penskalaan terhadap nilai-nilai masuk ke dalam suatu range tertentu. Hal ini dilakukan agar nilai *input* dan target *output* sesuai dengan *range* dari fungsi aktivasi yang digunakan dalam jaringan. Transformasi data dengan menggunakan interpolasi biasa, sehingga nilainya berada pada interval a sampai b (Siang,2009) :

$$\frac{X' - a}{b - a} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.27)$$

$$X' - a = (b - a) \left[\frac{x - x_{min}}{x_{max} - x_{min}} \right]$$

$$X'_i = \frac{(b - a)(x - x_{min})}{x_{max} - x_{min}} + a \quad (2.28)$$

Fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid biner dimana nilainya berada pada interval (0,1) yaitu tidak pernah tepat menyentuh 0 atau 1, maka data akan dinormalisasi ke interval 0,1 sampai 0,9. Transformasi yang digunakan adalah transformasi linear pada selang interval [a,b] adalah sebagai berikut:

$$X'_i = \frac{(b - a)(x - x_{min})}{x_{max} - x_{min}} + a$$

$$X'_i = \frac{(0.9 - 0.1)(x - x_{min})}{x_{max} - x_{min}} + 0.1$$

$$X'_i = \frac{0.8(x - x_{min})}{x_{max} - x_{min}} + 0.1 \quad (2.29)$$

Keterangan :

X' : Data hasil transformasi; ($i = 1, 2, \dots, n$)

x : Data asli

x_{min} : Data minimum

x_{max} : Data maksimum

a : Nilai interval terendah (0.1)

b : Nilai interval tertinggi (0.9)

2.8. Heteroskedastisitas

Suatu keadaan dikatakan heteroskedastisitas apabila suatu data memiliki variansi *error* yang tidak konstan untuk setiap observasi atau dengan kata lain

melanggar asumsi $Var(\varepsilon_t) = \sigma_t^2$. Heteroskedastisitas disebabkan oleh volatilitas data yang tinggi, dimana adanya fluktuasi yang cukup tajam pada data di periode waktu tertentu namun stabil pada periode waktu yang lain. Uji *Lagrange-Multiplier* (LM) merupakan pengujian untuk mengetahui masalah heteroskedastisitas dalam *time series* yang dikembangkan oleh Engle. Misalkan $\varepsilon_t = r_t - \mu_t$ adalah *residual* dari persamaan rata-rata. Deret residual kuadrat ε_t^2 digunakan untuk mengecek heteroskedastisitas bersyarat, yang juga dikenal sebagai efek ARCH. Untuk mengecek ada tidanya efek ARCH, dapat dilakukan menggunakan statistik uji *Lagrange Multiplier* (LM) yang diperkenalkan oleh (Tsay, 2010).

Hipotesis

$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k = 0$ (tidak ada efek ARCH/GARCH dalam residual sampai lag ke- k)

$H_1 : \exists \alpha_i \neq 0, i = 1, 2, \dots, k$ (ada efek ARCH/GARCH dalam residual sampai lag ke- k)

Taraf signifikansi: α

Statistic uji

$$F = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(N - 2m - 1)} \quad (2.29)$$

Dengan m =derajat bebas, $SSR_0 = \sum_{m+1}^N (\varepsilon_t^2 - \bar{\omega})$, $SSR_1 = \sum_{m+1}^N \hat{\varepsilon}_t^2$, $\bar{\omega}$ = rata-rata sampel dari ε_t^2 , $\hat{\varepsilon}_t^2 = residual$ kuadrat terkecil dan N =ukuran sampel.

Kriteria uji: tolak H_0 jika $p - value < \alpha$.

2.9. Generalized Autoregressive Conditional Heteroskedasticity (GARCH)

Penelitian yang dilakukan oleh Ping, dkk (2012) tentang *Forecasting Malaysian Gold Using GARCH* model. Diperoleh hasil bahwa model yang lebih cocok dalam memprediksi emas di malaysia adalah model GARCH dibandingkan dengan model ARIMA, dengan nilai error MSE dari GARCH adalah 0.809767. penelitian yang dilakukan oleh Mohamed E. M. Abdelhafez tentang Menggunakan Model GARCH untuk Pemodelan dan Peramalan Volatilitas Studi Empiris Pasar Saham Mesir. Hasil penelitian menunjukkan bahwa model GARCH (1,2), GARCH (2,1), TARARCH (1,1) dan EGARCH (1,1) sesuai untuk menganalisis data dari pasar saham Mesir. Masalah peramalan variasi kondisional menggunakan model ini. Telah ditunjukkan bahwa TARARCH (1,1) adalah model yang paling cocok. Selanjutnya, evaluasi peramalan menunjukkan bahwa model TARARCH (1,1)

mengungguli model GARCH lainnya. Penelitian yang dilakukan Serkan Aras, 2021 dengan judul susun model GARCH hybrid untuk memperkirakan volatilitas Bitcoin, hasil yang diperoleh GARCH (1,1) adalah model terbaik dapat mengungguli model TGARCH, IGARCH.

Sharma dan Vipul (2015) melakukan penelitian pada 21 index yang menggunakan harga harian selama periode 1 Januari 2000 sampai 30 November 2013 dengan menggunakan berbagai model *forecasting* GARCH memperoleh hasil bahwa GARCH merupakan model yang terbaik dibandingkan dengan model TGARCH, AVGARCH, NGARCH, APARCH, GJR, EGARCH. Berdasarkan *Ranked Worst Metric Count* GARCH menunjukkan best model karena berada di peringkat pertama. Kemudian untuk mengukur keakurasiannya dilakukanlah HMSE criterion dan GARCH menunjukkan performa yang luar biasa dibandingkan dengan model lainnya, GARCH memperoleh *lowest mean rank* yaitu 3,333 dan disusul oleh model TGARCH dengan nilai 3,476. Pada penelitian yang dilakukan Ping et al. (2013) yang berjudul "*Forecasting Malaysian Gold Using GARCH Model*" diperoleh hasil bahwa model yang lebih cocok dalam memprediksi emas di Malaysia adalah model GARCH dibandingkan model ARIMA hal ini ditunjukkan dari hasil *forecasting error* GARCH yang lebih rendah dimana *forecasting error* Garch 0,809767 sedangkan *forecasting error* dari ARIMA 0,812356.

Model yang dapat digunakan untuk mengatasi varians *error* yang tidak konstan dalam data deret waktu finansial adalah model *Autoregressive Conditional Heteroscedasticity* (ARCH) yang diperkenalkan pertama kali oleh Engle pada tahun 1982. Pada model ARCH variansi *error* (σ_t^2) dipengaruhi oleh *error* di periode sebelumnya ε_{t-1}^2 (Wei, 2006).

Model GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*) dikemukakan oleh Bollerslev pada tahun 1986 yang merupakan generalisasi dari model ARCH. GARCH dianggap memberikan hasil yang lebih sederhana karena menggunakan lebih sedikit parameter sehingga mengurangi tingkat kesalahan dalam perhitungan. Model GARCH digunakan untuk mengatasi orde yang terlalu besar pada model ARCH. Bentuk umum model GARCH (p, q) (Tsay, 2010):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-i}^2 \quad (2.30)$$

Keterangan :

σ_t^2 : variansi dari residual pada waktu t

α_0 : komponen konstanta

- α_i : parameter dari ARCH
 e_{t-i}^2 : kuadrat dari residual pada waktu $t - i$
 β_j : parameter dari GARCH
 σ_{t-i}^2 : variansi dari residual pada saat $t - j$

2.9.1. Estimasi Parameter GARCH

Misalkan model yang terbentuk yaitu model GARCH (1,0) maka berdasarkan persamaan (2.29), model GARCH (1,0) dapat dituliskan sebagai berikut:

$$\begin{aligned}\sigma_t^2 &= \alpha_0 + \alpha_1 e_{t-1}^2 \\ E(\sigma_t^2) &= E(\alpha_0) + E(\alpha_1 e_{t-1}^2) \\ \mu_{\sigma_t^2} &= \alpha_0 + \alpha_1 e_{t-1}^2\end{aligned}$$

Sehingga parameter model yang akan ditaksir adalah α_0 dan α_1 . Adapun fungsi kepadatan peluang dari $\sigma_t^2 \sim N(\mu, \sigma^2)$ yaitu:

$$\begin{aligned}f(\sigma_t^2; \alpha_0, \alpha_1) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2} (\sigma_t^2 - \mu_{\sigma_t^2})^2\right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2} (\sigma_t^2 - \alpha_0 - \alpha_1 e_{t-1}^2)^2\right)\end{aligned}$$

Selanjutnya fungsi *likelihood* dapat dituliskan seperti persamaan (2.31) berikut:

$$L(a_0, a_1; \sigma_t^2) = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} \exp\left(-\frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2}\right) \quad (2.31)$$

Untuk memaksimumkan nilai fungsi $L(a_0, a_1; \sigma_t^2)$ dapat diperoleh dengan cara memaksimumkan fungsi *ln-likelihood*nya. Misalkan l merupakan fungsi *ln-likelihood* dari Persamaan (2.31), maka:

$$\begin{aligned}l &= \ln(L(a_0, a_1; \sigma_t^2)) \\ &= \ln\left(\frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}}\right) + \ln\left(\exp\left(-\frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2}\right)\right) \\ &= \ln 1 - \ln((2\pi\sigma^2)^{\frac{n}{2}}) - \frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2} \\ &= -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2}\end{aligned}$$

Untuk mendapatkan parameter α_0 dan α_1 dilakukan dengan memaksimumkan l yang membuat $\frac{\partial l}{\partial(\alpha_0, \alpha_1)} = 0$

Turunan pertama terhadap parameter α_0

$$\begin{aligned}
\frac{\partial l}{\partial \alpha_0} &= \frac{\partial \left(-\frac{n}{2} \ln 2\pi\sigma^2 \right)}{\partial \alpha_0} + \frac{\partial \left(-\frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2} \right)}{\partial \alpha_0} \\
0 &= 0 - \frac{1}{\sigma^2} \sum_{t=2}^n \sigma_t^2 - a_0 - a_1 e_{t-1}^2 (-1) \\
0 &= \frac{1}{\sigma^2} \left(-n\alpha_0 + \sum_{t=2}^n \sigma_t^2 - \alpha_1 \sum_{t=2}^n e_{t-1}^2 \right) \\
n\alpha_0 &= \sum_{t=2}^n \sigma_t^2 - \alpha_1 \sum_{t=2}^n e_{t-1}^2 \\
\hat{\alpha}_0 &= \frac{1}{n} \left(\sum_{t=2}^n \sigma_t^2 - \alpha_1 \sum_{t=2}^n e_{t-1}^2 \right) \tag{2.32}
\end{aligned}$$

Turunan pertama terhadap parameter α_1

$$\begin{aligned}
\frac{\partial l}{\partial \alpha_1} &= \frac{\partial \left(-\frac{n}{2} \ln 2\pi\sigma^2 \right)}{\partial \alpha_1} + \frac{\partial \left(-\frac{1}{2} \sum_{t=2}^n \frac{(\sigma_t^2 - a_0 - a_1 e_{t-1}^2)^2}{\sigma^2} \right)}{\partial \alpha_1} \\
0 &= 0 - \frac{1}{\sigma^2} \sum_{t=2}^n \sigma_t^2 - a_0 - a_1 e_{t-1}^2 (-e_{t-1}^2) \\
0 &= \frac{1}{\sigma^2} \left(\sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - a_0 \sum_{t=2}^n e_{t-1}^2 - \alpha_1 \sum_{t=2}^n e_{t-1}^4 \right) \\
\alpha_1 \sum_{t=2}^n e_{t-1}^4 &= \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - a_0 \sum_{t=2}^n e_{t-1}^2 \tag{2.33}
\end{aligned}$$

Untuk mendapatkan estimasi parameter dari α_1 , maka persamaan (2.32) disubstitusikan ke persamaan (2.33), maka:

$$\begin{aligned}
\alpha_1 \sum_{t=2}^n e_{t-1}^4 &= \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - \frac{1}{n} \left(\sum_{t=2}^n \sigma_t^2 - \alpha_1 \sum_{t=2}^n e_{t-1}^2 \right) \sum_{t=2}^n e_{t-1}^2 \\
\alpha_1 \sum_{t=2}^n e_{t-1}^4 &= \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - \frac{1}{n} \sum_{t=2}^n \sigma_t^2 \sum_{t=2}^n e_{t-1}^2 + \frac{\alpha_1}{n} \left(\sum_{t=2}^n e_{t-1}^2 \right)^2 \\
\alpha_1 \sum_{t=2}^n e_{t-1}^4 - \frac{\alpha_1}{n} \left(\sum_{t=2}^n e_{t-1}^2 \right)^2 &= \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - \frac{1}{n} \sum_{t=2}^n \sigma_t^2 \sum_{t=2}^n e_{t-1}^2 \\
\alpha_1 \left(\frac{n \sum_{t=2}^n e_{t-1}^4 - \left(\sum_{t=2}^n e_{t-1}^2 \right)^2}{n} \right) &= \frac{n \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - \sum_{t=2}^n \sigma_t^2 \sum_{t=2}^n e_{t-1}^2}{n}
\end{aligned}$$

$$\hat{\alpha}_1 = \frac{n \sum_{t=2}^n \sigma_t^2 e_{t-1}^2 - \sum_{t=2}^n \sigma_t^2 \sum_{t=2}^n e_{t-1}^2}{n \sum_{t=2}^n e_{t-1}^4 - \alpha_1 (\sum_{t=2}^n e_{t-1}^2)^2} \quad (2.34)$$

2.10. Harga Saham

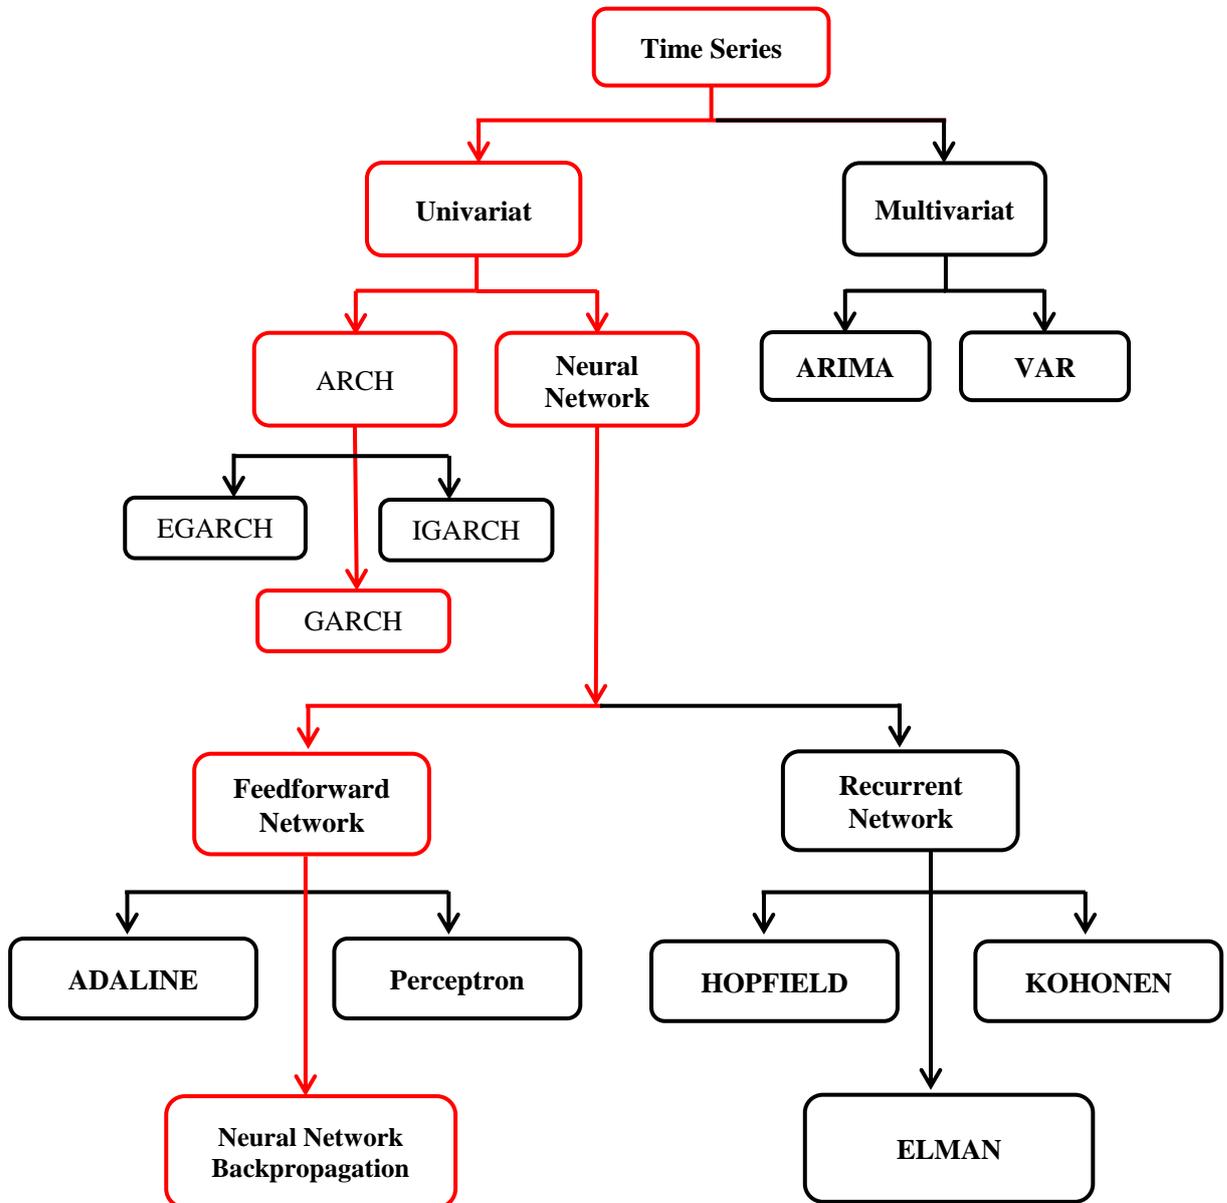
Saham merupakan surat berharga atau bukti posisi kepemilikan seseorang dalam perusahaan dan pemilik saham berhak atas keuntungan dari perusahaan dan besarnya keuntungan yang didapat sesuai dengan besarnya jumlah saham yang dimiliki. Disamping itu saham biasa juga memiliki hak untuk memilih (*vote*) untuk keputusan-keputusan yang memerlukan pemungutan suara seperti pembagian deviden, pengangkatan direksi dan komisaris. Saham yang dapat dijadikan wahana investasi adalah yang dikenal sebagai emisi efisien yang diperdagangkan secara umum, yaitu saham yang tersedia bagi masyarakat (Ramadhona, 2004).

Bursa saham adalah pasar umum untuk memperdagangkan saham perusahaan dan sejenisnya. Pasar saham diatur oleh badan pengawas dan anggota yang telah terdaftar pada pasar saham tersebut. Pasar saham mempertemukan antara investor saham dan perusahaan yang menjual saham. Pasar saham yang menetapkan harga saham disesuaikan dengan penawaran dan permintaan saham tersebut. Jika pembelian saham meningkat maka saham tersebut bertambah harganya, namun jika penjualan lebih banyak, maka harga saham turun. Salah satu hal yang ingin diketahui seseorang untuk menghasilkan keuntungan dengan berinvestasi. Ada dua metode dasar yaitu analisis teknikal dan analisis fundamental. Analisis fundamental mengacu pada analisis perusahaan pada laporan keuangan yang ditemukan, tren bisnis, kondisi umum ekonomi dan lainnya. Analisis fundamental digunakan untuk menyelidiki perusahaan terkait dengan potensi pertumbuhan pendapatan di masa depan. Dimulai dengan analisis ekonomi: pertumbuhan ekonomi, inflasi, pengangguran, dan levelnya. Dengan mempertimbangkan indikator yang mempengaruhi ekonomi, analisis keuangan dapat memperkirakan tingkat produk domestik bruto (PDB) masa depan. Kunci utama dari analisis fundamental adalah analisis ekonomi, analisis industri, analisis perusahaan, dan analisis rasio. Analisis teknikal didasarkan pada pemeriksaan pergerakan harga dan volume individu saham atau pasar secara keseluruhan. Hal itu membantu dalam mencari arah pergerakan pasar, sektor atau saham.

Harga penutupan adalah harga yang muncul saat bursa tutup. Harga penutupan saham ini sangat penting, karena menjadi acuan untuk harga pembukaan pada keesokan harinya. Harga penutupan saham biasanya digunakan untuk memprediksi harga saham periode berikutnya. Prediksi harga saham ini

sangat membantu pelaku pasar untuk memberikan saran mengenai harga saham yang akan dijual atau dibeli oleh pelaku pasar (Fakhruddin, 2006).

2.11. Kerangka Konseptual



Gambar 2. 6 Kerangka Konseptual