

**IMPLEMENTASI METODE *HYBRID AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE (ARIMA) – ARTIFICIAL NEURAL NETWORK (ANN)*
DALAM PERAMALAN HARGA MATA UANG KRIPTO**

(Skripsi)

Oleh

FARREL RIZKIANSYAH

1817031048



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

ABSTRACT

THE IMPLEMENTATION OF *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)* – *ARTIFICIAL NEURAL NETWORK (ANN)* METHOD IN CRYPTOCURRENCY PRICE FORECASTING

By

FARREL RIZKIANSYAH

Cryptocurrencies are one of the most popular investment instruments, especially during the COVID-19 pandemic. Investments made in cryptocurrencies or other instruments are primarily aimed at making a profit. A step that can be used to earn profits through investing in either cryptocurrencies or other instruments is to project prices over several periods in the future. The science that can be used to make price projections is to use statistics. ARIMA is the most commonly used method in statistical disciplines for forecasting. The limitation of ARIMA method is difficult to define non-linear components contained in data that has high fluctuations, one of which is financial data. ANN is a model that has three main layers, namely the input layer, hidden layer and output layer. These three layers in the ANN model are expected to be able to capture non-linear data patterns in data with high value fluctuations. Therefore, the ARIMA - ANN hybrid method was introduced which is expected to be able to make predictions and forecasts. The ARIMA-ANN hybrid method consists of 2 main models. The first model is a model that predicts the prediction results from ARIMA. The second model is a model that predicts residual data from ARIMA predictions. The hybrid model in this study was able to produce an MSE value of 0.05557, an RMSE value of 0.2357 and a MAPE value of 0.08867.

Keywords: hybrid ARIMA - ANN, ANN, ARIMA, neural network, time series, hybrid model, cryptocurrency, prediction, forecasting

ABSTRAK

IMPLEMENTASI METODE *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – ARTIFICIAL NEURAL NETWORK (ANN)* DALAM PERAMALAN HARGA MATA UANG KRIPTO

Oleh

FARREL RIZKIANSYAH

Mata uang kripto merupakan salah satu instrumen investasi yang populer terutama pada masa pandemi COVID - 19. Investasi yang dilakukan pada mata uang kripto ataupun pada instrumen lainnya utamanya bertujuan untuk mendapatkan keuntungan. Langkah yang dapat digunakan untuk mendapatkan keuntungan melalui investasi baik pada mata uang kripto ataupun instrumen lainnya adalah dengan memproyeksikan harga pada beberapa periode kedepan. Ilmu yang dapat digunakan untuk melakukan proyeksi harga adalah dengan menggunakan statistika. ARIMA merupakan metode yang paling umum digunakan dalam disiplin ilmu statistika untuk melakukan peramalan. Keterbatasan ARIMA adalah sulit untuk mendefinisikan komponen non linear yang terdapat pada data yang memiliki fluktuasi nilai yang tinggi, salah satunya pada data finansial. ANN merupakan model yang memiliki tiga layer utama, yaitu *input layer*, *hidden layer* dan *output layer*. Ketiga layer pada model ANN diharapkan mampu untuk menangkap pola data nonlinear pada data dengan fluktuasi nilai yang tinggi. Oleh karena itu, dicetuskan metode hybrid ARIMA - ANN yang diharapkan mampu melakukan prediksi serta peramalan. Metode hybrid ARIMA-ANN terdiri atas 2 model utama. Model pertama merupakan model yang memprediksikan hasil prediksi dari ARIMA. Model kedua merupakan model yang memprediksikan data residual dari prediksi ARIMA. Model hybrid pada penelitian ini mampu menghasilkan nilai MSE sebesar 0,05557, nilai RMSE sebesar 0,2357 dan nilai MAPE sebesar 0,08867.

Kata Kunci: *Hybrid ARIMA - ANN, ANN, ARIMA, Neural Network, Deret*

Waktu, Model Hybrid, Mata uang kripto, prediksi, peramalan

IMPLEMENTASI METODE *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – ARTIFICIAL NEURAL NETWORK (ANN)* DALAM PERAMALAN HARGA MATA UANG KRIPTO

Oleh

FARREL RIZKIANSYAH

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG

2022

Judul Skripsi

: IMPLEMENTASI METODE *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – ARTIFICIAL NEURAL NETWORK (ANN)* DALAM PERAMALAN HARGA MATA UANG KRIPTO

Nama Mahasiswa

: Farrel Rizkiansyah

Nomor Pokok Mahasiswa

: 1817031048

Program Studi

: Matematika

Fakultas

: Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

A handwritten signature in black ink, appearing to be 'Dian Kurniasari', with a large flourish extending from the bottom right.

Dian Kurniasari S.Si., M.Sc.
NIP. 196903051996032001

A handwritten signature in black ink, appearing to be 'Notiragayu', with a large flourish extending from the bottom right.

Dr. Notiragayu S.Si., M.Si.
NIP. 197311092000122001

2. Ketua Jurusan Matematika

A handwritten signature in black ink, appearing to be 'Aang Nuryaman', with a large flourish extending from the bottom right.

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

MENGESAHKAN

1. Tim Penguji

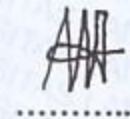
Ketua

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



Sekretaris

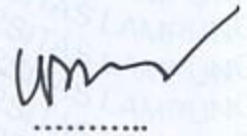
: **Dr. Notiragayu S.Si., M.Si.**



Penguji

Bukan Pembimbing

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



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Suripto Dwi Yuwono, S.Si., M.T.

NIP. 19740705 200003 1 001

Tanggal Lulus Ujian Skripsi : 03 Agustus 2022

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini :

Nama Mahasiswa : Farrel Rizkiansyah

Nomor Pokok Mahasiswa : 1817031048

Jurusan : Matematika

Judul Skripsi : **IMPLEMENTASI METODE *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – ARTIFICIAL NEURAL NETWORK (ANN)* DALAM PERAMALAN HARGA MATA UANG KRIPTO**

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

Bandar Lampung, 03 Agustus 2022

Penulis,



Farrel Rizkiansyah

RIWAYAT HIDUP

Penulis bernama lengkap Farrel Rizkiansyah, dilahirkan pada tanggal 30 Maret 2000 di Tangerang. Penulis merupakan putra tunggal dari Bapak Firdaus H. Lubis dan Ibu Nina Susanti S.Pd.

Penulis mengawali pendidikan di Taman Kanak-Kanak (TK) Al-Mutmainnah pada tahun 2005-2006. Kemudian menempuh pendidikan Sekolah dasar (SD) di SDIT Al-Qomar pada tahun 2006 – 2012. Kemudian melanjutkan ke Sekolah Menengah Pertama di SMPN 249 Jakarta pada tahun 2012-2015. Selanjutnya belajar pada jenjang Sekolah Menengah Atas di SMAN 95 Jakarta pada tahun 2015-2018. Pada tahun 2018 penulis terdaftar sebagai mahasiswa Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Pada Tahun 2020 penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Tegal Alur, Kecamatan Kalideres, sebagai bentuk pengabdian kepada masyarakat. Pada tahun yang sama penulis juga melaksanakan Kuliah Kerja Praktik (KP) di Faster English Cengkareng sebagai bentuk aplikasi bidang ilmu di dunia kerja.

KATA INSPIRASI

“Dan bersabarlah kamu. Sesungguhnya janji Allah adalah benar.”

(Q.S Ar-Rum : 60)

“Dan hanya kepada Tuhanmulah hendaknya kamu berharap.”

(Q.S Al-Insyirah : 8)

“Sungguh Atas Kehendak Allah Semua Ini Terwujud, Tiada Kekuatan Kecuali Dengan Pertolongan Allah.”

(Q.S Al-Kahfi : 39)

“Seseorang Yang Bersabar Tidak Akan Pernah Kehilangan Kesuksesan Meskipun Membutuhkan Waktu Yang Lama Untuk Mencapainya.”

(Ali Bin Abi Thalib)

“Do what you love and love what you do”

(Nina Susanti S.Pd.)

“To succeed, work hard, never give up and above all, cherish a magnificent obsession.”

(Walt Disney)

PERSEMBAHAN

Alhamdulillah, puji dan syukur kepada Allah SWT atas nikmat serta hidayahnya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya.

Oleh karena itu, dengan rasa syukur dan bahagia saya persembahkan rasa terimakasih saya kepada

Ibu dan Ayah

Tidak ada kata yang dapat aku sampaikan untuk kalian kecuali ucapan terimakasih atas semua yang telah kalian berikan untukku. Cinta, kasih sayang, motivasi, waktu, pengorbanan yang belum bisa aku balas, serta doa dan sujud yang selalu menantikan keberhasilanku dengan sabar dan penuh pengertian. Terimakasih karena selalu mendoakan dan mendukung setiap langkah yang aku pilih. 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.

Dosen Pembimbing dan Pembahas

Terimakasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

Almamater Tercinta Universitas Lampung

SANWACANA

Segala puji dan syukur penulis ucapkan kepada Allah SWT atas segala nikmat dan karunia-Nya yang tak terhingga sehingga penulis dapat menyelesaikan skripsi yang berjudul ***“Implementasi Metode Hybrid Autoregressive Integrated Moving Average (ARIMA) – Artificial Neural Network (ANN) Dalam Peramalan Harga Mata Uang Kripto”***. Dalam penulisan skripsi ini tidak dapat terselesaikan tanpa adanya bimbingan, bantuan dan dukungan dari berbagai pihak. Sehingga, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Ibu Dian Kurniasari S.Si., M.Sc. selaku dosen pembimbing I sekaligus dosen pembimbing akademik yang senantiasa membimbing dengan sabar, memberi masukan serta saran serta mendukung penulis dalam menyelesaikan skripsi ini.
2. Ibu Dr. Notiragayu S.Si., M.Si. selaku dosen pembimbing II memberikan bimbingan, pengarahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
3. Bapak Ir. Warsono, M.S., Ph.D. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga skripsi ini dapat terselesaikan.
4. Bapak Dr.Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Seluruh dosen, staff, karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Teruntuk kedua orang tuaku tercinta, Ayah Firdaus H. Lubis dan Ibu Nina Susanti S.Pd. terimakasih atas doa, dukungan, pengorbanan, cinta kasih, perhatian, demi kesuksesan penulis semoga dikemudian hari dapat membahagiakan dan menjadi kebanggan kalian.

8. Teruntuk sahabat ku sejak SMA, Izzah, Dimas, Fikri, Luthfi, Aldo, terimakasih atas doa, dorongan, saran, dan motivasi, serta bantuan dalam menyelesaikan skripsi ini.
9. Teruntuk sahabat kuliah ku, Isad, Fatur, Ferdy, Naufal, Hamzah, Timothy, Bang Desfan, Shavira Z., Anisa D. P., Selviani S., Danu, terimakasih atas pengalaman serta dukungan terhadap penulis dari sejak awal perkuliahan hingga selesai.
10. Semua teman sejurusan matematika 2018 dan teman kelas B yang telah membantu serta memberikan semangat kepada penulis yang mana tidak bisa disebutkan satu persatu.
11. Orang-orang baik yang namanya tidak bisa saya sebutkan satu persatu yang telah menjadi teman terbaik penulis yang selalu memberikan semangat dan menemani penulis dalam keadaan apapun serta telah memberikan pengalaman dan banyak cerita selama masa perkuliahan.
12. Teman-teman seperbimbinganku Ferzy, Zaenal, Maydia, Virda, Dalfa, Luthfia, Putri, Alifia, Feby, Rekti, Joshua, Oktin, terimakasih atas doa, motivasi, dukungan, semangat, yang selalu di berikan kepada penulis. Semoga kalian menjadi orang yang sukses dan bahagia dimanapun kalian berada. See you on top.
13. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 03 Agustus 2022

Penulis,

Farrel Rizkiansyah

DAFTAR ISI

I. PENDAHULUAN.....	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	4
1.3 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA.....	5
2.1 Peramalan	5
2.2 <i>Data Mining</i>	6
2.3 <i>Statistical Learning</i>	8
2.4 <i>Machine Learning</i> (Pembelajaran Mesin).....	10
2.5 <i>Autoregressive Integrated Moving Average</i> (ARIMA).....	11
2.6 <i>Artificial Neural Network</i> (ANN).....	13
2.7 ARIMA - ANN (<i>Hybrid</i>).....	20
2.8 Akurasi	23
2.9 Polygon Matic	24
III. METODOLOGI PENELITIAN	26
3.1 Waktu dan Tempat Penelitian	26
3.2 Data Penelitian	26
3.3 Metode Penelitian.....	27
IV. HASIL DAN PEMBAHASAN.....	30
4.1 Proses <i>Input</i> Data.....	30
4.2 Prediksi data dengan ARIMA	32

4.3 Prediksi dengan model <i>hybrid</i> ARIMA-ANN.....	37
4.4 Peramalan dengan model <i>hybrid</i>	51
V. KESIMPULAN DAN SARAN	54
5.1 Kesimpulan.....	54
5.2 Saran	54

DAFTAR PUSTAKA

LAMPIRAN

DAFTAR TABEL

Tabel	Halaman
1. Ilustrasi data <i>time series</i> menjadi data <i>supervised learning</i>	8
2. Kriteria nilai MAPE	24
3. Data mata uang kripto Matic.....	27
4. Plot prediksi menggunakan model ANN pertama	48
5. Plot prediksi menggunakan model ANN kedua.....	49
6. Visualisasi model hybrid dan nilai evaluasi.....	50
7. Plot peramalan menggunakan model pertama untuk kedua skema	52
8. Plot peramalan menggunakan model kedua	52
9. Plot peramalan model hybrid	53

DAFTAR GAMBAR

Gambar	Halaman
1. Struktur ANN.....	16
2. <i>Workflow</i> ARIMA - ANN.....	29
3. Proses <i>input</i> data	30
4. Data kripto Matic	31
5. <i>Plot data mata uang kripto Matic</i>	31
6. Nilai <i>p-value</i> sebelum differencing	32
7. Nilai <i>p-value</i> setelah differencing	33
8. <i>Syntak</i> plot ACF dan PACF	33
9. Hasil plot ACF dan PACF	34
10. <i>Syntak</i> untuk menampilkan summary model	34
11. <i>Summary</i> model ARIMA	35
12. Plot data aktual dan data prediksi ARIMA	35
13. Nilai akurasi untuk data prediksi ARIMA	36
14. Plot data residual.....	37
15. <i>splitting</i> data prediksi menjadi 70% <i>training</i> dan 30% <i>testing</i>	38
16. <i>splitting</i> data prediksi menjadi 60% <i>training</i> dan 40% <i>testing</i>	38
17. Struktur data <i>time series</i> menjadi <i>supervised learning</i>	39

18. <i>Hyperparameter tuning</i> model pertama untuk skema 70% <i>training</i> dan 30% <i>testing</i>	40
19. <i>Hyperparameter tuning</i> model pertama untuk skema 60% <i>training</i> dan 40% <i>testing</i>	41
20. <i>Input</i> nilai parameter dan <i>training</i> model pertama untuk skema 70% <i>training</i> dan 30% <i>testing</i>	42
21. <i>Input</i> nilai parameter dan <i>training</i> model pertama untuk skema 60% <i>training</i> dan 40% <i>testing</i>	43
22. <i>Hyperparameter tuning</i> model kedua untuk skema 70% <i>training</i> dan 30% <i>testing</i>	44
23. <i>Hyperparameter tuning</i> model kedua untuk skema 60% <i>training</i> dan 40% <i>testing</i>	45
24. <i>Input</i> nilai parameter dan <i>training</i> model kedua untuk skema 70% <i>training</i> dan 30% <i>testing</i>	46
25. <i>Input</i> nilai parameter dan <i>training</i> model kedua untuk skema 60% <i>training</i> dan 40% <i>testing</i>	47
26. Proses kombinasi antara model pertama dengan model kedua.....	50
27. Proses peramalan	51

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Investasi mata uang kripto atau *cryptocurrency* mulai populer dewasa ini. Kehadiran mata uang kripto merupakan sebuah fenomena yang muncul karena tuntutan pelaku usaha yang menginginkan proses transaksi yang lebih cepat dan terpercaya (Noorsanti, dkk., 2018). Mata uang kripto adalah mata uang digital yang bisa digunakan untuk bertransaksi secara daring. Dari segi peraturan perundangan yang berlaku di negara Republik Indonesia, mata uang kripto memang tidak diakui sebagai alat tukar yang sah, tetapi masyarakat tidak dilarang untuk memanfaatkannya dan resiko yang timbul dari pemakaian mata uang kripto merupakan tanggung jawab pribadi masing-masing (Noorsanti, dkk., 2018). Di Indonesia, mata uang kripto telah dijadikan salah satu aset untuk bisa diinvestasikan. Dunia kripto menawarkan *return* yang tinggi bagi para investor yang ingin menanamkan modalnya disana. Nilai *return* yang tinggi tentu saja diikuti dengan tingkat resiko yang tinggi pula. Fluktuasi harga adalah suatu keharusan dalam setiap bisnis, termasuk harga mata uang kripto. Oleh karena itu manusia membutuhkan suatu perangkat atau aplikasi yang dapat membantu dalam melakukan peramalan secara akurat (Ulumuddin, dkk., 2020).

Bitcoin merupakan jenis mata uang kripto pertama sekaligus memiliki kapitalisasi pasar terbesar saat ini. Bitcoin pertama kali diluncurkan pada tahun 2008 (Addinanto, 2018). Bitcoin dan Ethereum merupakan contoh dari mata uang kripto yang sudah cukup dikenal dan sudah memiliki harga yang relatif lebih tinggi di

tahun 2022. Harga tertinggi yang pernah dicapai oleh Bitcoin adalah pada tahun 2021 yakni berkisar 900 juta rupiah per koin dan harga tertinggi yang pernah dicapai oleh Ethereum yakni berkisar 60 juta rupiah per koin. Alternatif lain dari Bitcoin dan Ethereum adalah Matic. Matic memiliki harga yang lebih terjangkau jika dibandingkan dengan Bitcoin dan Ethereum. Matic diluncurkan pada tahun 2017 dan dikembangkan oleh Sandeep Nailwal yang juga merupakan pendiri Ethereum (Johnson, 2021). Harga tertinggi yang pernah dicapai oleh Matic hingga saat penulisan skripsi ini adalah berkisar 40 ribu rupiah per koin. Hal tersebut menjadikan Matic sebagai alternatif lain instrumen investasi selain Bitcoin dan Ethereum karena memiliki harga yang relatif terjangkau.

Peramalan harga merupakan salah satu analisis yang bisa digunakan sebelum berinvestasi pada mata uang kripto. Terdapat berbagai macam metode yang bisa digunakan. Metode untuk data deret waktu yang umum digunakan adalah model *Autoregressive Integrated Moving Average (ARIMA)*. Popularitas model ARIMA adalah karena sifat statistiknya serta metodologi Box-Jenkins yang terkenal dalam proses pembuatan model. Keterbatasan utama dalam model ARIMA adalah menjadikan linearitas sebagai asumsi. Korelasi linear struktur diasumsikan di antara nilai-nilai deret waktu sebelumnya sehingga tidak ada pola non-linear yang dapat ditangkap oleh model ARIMA (Zhang, 2001). Metode ARIMA lebih banyak digunakan untuk meramalkan data dalam jangka waktu singkat. Data deret waktu yang memiliki pola non-linear lebih sulit untuk diramalkan dengan metode ARIMA.

Artificial Neural Network (ANN) adalah metode yang menggunakan prinsip jaringan saraf pada manusia. ANN memiliki 3 struktur utama yaitu *input layer*, *hidden layer* dan *output layer*. Metode ANN banyak digunakan untuk kasus regresi, klasifikasi dan juga *time series*. Metode ANN tidak memerlukan asumsi yang harus dipenuhi dalam pengolahan data.

Keterbatasan yang dimiliki oleh metode ARIMA dapat diatasi dengan mengkombinasikan ARIMA dengan model *Artificial Neural Network* (ANN) agar pola data non-linear dapat didefinisikan dan membuat akurasi dalam melakukan peramalan menjadi lebih baik. Jaringan saraf tiruan (JST) atau ANN telah dipelajari secara ekstensif dan digunakan dalam peramalan deret waktu. Keuntungan utama dari jaringan saraf adalah kemampuan pemodelan nonlinier yang fleksibel. Model ANN akan terbentuk secara adaptif berdasarkan data yang telah ada (Zhang, 2001). Kelebihan utama dari model ANN adalah model tersebut dapat mendefinisikan pola non linear dalam data time series sehingga kombinasi antara model ARIMA dan ANN diharapkan dapat memaksimalkan akurasi hasil peramalan harga dari mata uang kripto yang memiliki pola data yang cenderung acak.

Hasil yang didapatkan dalam proses peramalan belum tentu sesuai dengan keadaan aktualnya. Perbedaan harga akan terjadi antara hasil peramalan dengan harga aktualnya yang biasa disebut dengan *error* atau galat. Alat yang digunakan untuk mengukur tingkat *error* atau akurasi adalah dengan menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE).

Penelitian mengenai ARIMA dan ANN sudah pernah dilakukan. Penelitian yang dilakukan oleh Machmuddin dan Brodjol, 2020 membandingkan metode ARIMA dan ANN untuk meramalkan suhu udara di kota Surabaya. Hasilnya adalah performa dari metode ANN lebih baik dari pada metode ARIMA. Penelitian lain mengenai ANN dilakukan oleh Moghaddam, dkk., 2016 yang membahas mengenai prediksi index saham dengan menggunakan metode ANN.

Penelitian mengenai *Hybrid* ARIMA – ANN untuk meramalkan jumlah penumpang penerbangan di terminal 1 Bandara Internasional Juanda dilakukan oleh Lucciana, 2017 dan hasil yang diperoleh menyatakan bahwa *Hybrid* ARIMA – ANN memiliki akurasi yang baik yaitu dengan nilai MAPE sebesar 4,13%.

Penelitian oleh Zhang, 2001 melakukan prediksi dengan menggunakan metode *Hybrid* ARIMA – ANN dan membandingkan hasil dari ARIMA, ANN dan metode *Hybrid* pada 3 jenis data saham. Dari perbandingan ketiga metode tersebut, didapatkan hasil bahwa metode *Hybrid* ARIMA – ANN memiliki nilai MSE yang cenderung lebih kecil jika dibandingkan dengan ARIMA atau ANN saja.

Berdasarkan pemaparan di atas, penulis tertarik untuk melakukan penelitian tentang penerapan metode *Hybrid* ARIMA – ANN untuk mengatasi permasalahan asumsi linearitas pada model ARIMA dan dapat meramalkan harga mata uang kripto sehingga dapat digunakan oleh calon investor dalam mengambil keputusan mengenai waktu yang tepat untuk bisa berinvestasi pada instrument kripto Matic.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini yaitu :

1. Mengetahui performa model dari metode *hybrid* ARIMA-ANN terhadap harga mata uang kripto Matic
2. Mengetahui peramalan dari model *hybrid* ARIMA-ANN terhadap harga mata uang kripto Matic.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut :

1. Memberikan pengetahuan terkait pemodelan dan prediksi harga mata uang kripto Matic.
2. Sebagai sumber ilmu pengetahuan bagi penulis maupun pembaca.
3. Dapat menjadi referensi bagi peneliti selanjutnya tentang metode *Hybrid* ARIMA-ANN maupun tentang prediksi harga mata uang kripto Matic.

II. TINJAUAN PUSTAKA

2.1 Peramalan

Peramalan adalah prediksi beberapa peristiwa di masa mendatang atau di masa depan. Peramalan adalah masalah penting yang mencakup banyak bidang, termasuk bisnis dan industri, pemerintah, ekonomi, ilmu lingkungan, kedokteran, ilmu sosial, politik dan keuangan. masalah prediksi sering diklasifikasikan sebagai jangka pendek, jangka menengah dan jangka panjang (Montgomery, dkk., 2015). Sedangkan menurut Heizer dan Render (2015), peramalan (*forecasting*) adalah suatu seni dan ilmu pengetahuan dalam memprediksi peristiwa pada masa mendatang. Peramalan melibatkan pengambilan data historis (penjualan tahun lalu) dan memproyeksikannya pada masa mendatang dengan model matematika. Berdasarkan kedua pengertian tersebut, kita dapat menyimpulkan bahwa konsep peramalan adalah suatu metode atau proses untuk memperkirakan sesuatu di masa mendatang berdasarkan informasi atau data masa lalu yang relevan.

Meskipun berbagai situasi masalah yang memerlukan prakiraan, hanya ada dua jenis teknik peramalan—metode kualitatif dan metode kuantitatif (Montgomery, dkk., 2015), yaitu :

1. Peramalan kuantitatif merupakan peramalan yang menggunakan data-data kuantitatif yang terdapat di masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Hasil pengamatan sangat bergantung pada metode yang digunakan, sehingga setiap metode memiliki hasil peramalan yang berbeda pula.

2. Peramalan kualitatif merupakan metode yang pengambilan datanya didasarkan pada kualitatif yang diambil pada masa lalu, seperti intuisi pengambilan keputusan, emosi, pengalaman pribadi dan sistem nilai. Hasil dari peramalan kualitatif didasarkan pada pengamatan kejadian-kejadian di masa lalu yang digabung dengan pemikiran dari penyusunnya

2.2 Data Mining

Data mining adalah penambangan atau penemuan informasi baru dengan mencari pola atau aturan tertentu dari sejumlah data yang sangat besar (Davies dan Beynon 2004). *Data mining* juga disebut sebagai serangkaian proses untuk memperoleh nilai tambah berupa pengetahuan yang selama ini tidak diketahui secara manual dari suatu kumpulan data (Pramudiono, 2003). *Data mining* sering juga disebut sebagai *knowledge discovery in database* (KDD) yang meliputi pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam himpunan data berukuran besar (Santosa, B., 2007). *Data mining* dapat dikatakan juga sebagai kegiatan menemukan pola yang menarik dari data dalam jumlah besar, data dapat disimpan dalam basis data, *data warehouse* atau penyimpanan informasi lainnya. *Data mining* berkaitan dengan bidang ilmu – ilmu lain seperti sistem basis data, *data warehousing*, statistika, pembelajaran mesin, *information retrieval* dan komputasi tingkat tinggi. *Data mining* juga didukung oleh ilmu lain seperti jaringan syaraf tiruan, pengenalan pola, data spasial, analisis, basis data gambar dan *signal processing* (Han dan Kamber, 2006). *Data mining* didefinisikan sebagai proses menemukan pola-pola dalam data. Proses ini otomatis atau seringnya semi otomatis. Pola yang ditemukan harus penuh arti dan pola tersebut memberikan keuntungan, biasanya keuntungan secara ekonomi (James, G., dkk., 2014).

Kesimpulan yang dapat diambil berdasarkan pemaparan di atas adalah bahwa *data mining* adalah suatu teknik menggali informasi berharga yang terpendam atau tersembunyi pada suatu koleksi data yang sangat besar sehingga ditemukan suatu

pola tertentu yang sebelumnya tidak diketahui (Han dan Kamber, 2006). Oleh karena itu, *data mining* memiliki keterkaitan dari bidang ilmu lain seperti kecerdasan buatan (*artificial intelligent*), pembelajaran mesin, statistik dan basis data (Arthur, 1959). Metode yang sering disebut dalam literatur *data mining* antara lain klastering, klasifikasi, aturan asosiasi, jaringan saraf tiruan dan algoritma genetik (Pramudiono, 2003).

2.2.1 Data Preprocessing

Data preprocessing adalah tahap persiapan data sebelum data diolah lebih lanjut dan didapatkan suatu informasi tertentu. *Data preprocessing* meliputi identifikasi data yang hilang, identifikasi *outlier*, transformasi data hingga merubah struktur data menjadi bentuk *supervised learning*. ANN merupakan model yang terdiri dari *input layer*, *hidden layer* dan *output layer*. *Input layer* dari ANN merupakan variabel bebas atau variabel *predictor* yang bisa ditulis menjadi bentuk fungsi berikut :

$$y = f(x_1, x_2, \dots, x_p) \quad (2.1)$$

di mana :

- x_1, x_2, \dots, x_p : variabel bebas (*input*)
- y : variabel waktu sebanyak p hari yang lalu.
- p : indeks hari

Nilai *input* yang digunakan dalam data *time series* merupakan nilai data masa lalu sedangkan nilai *output* merupakan nilai di masa mendatang (Zhang, dkk., 1998). Oleh karena itu, bentuk data *time series* harus diubah menjadi bentuk *supervised learning* dan dapat ditulis menjadi fungsi berikut :

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}) \quad (2.2)$$

di mana :

- y_t : variabel target waktu

y_{t-1}, \dots, y_{t-p} : variabel waktu sebanyak p hari yang lalu.

p : indeks hari

Tabel 1. Ilustrasi data *time series* menjadi data *supervised learning*

Hari	Data	Hari	y_{t-3}	y_{t-2}	y_{t-1}	y_t
1	10	1	10	20	30	40
2	20	2	20	30	40	50
3	30	3	30	40	50	60
4	40	4	40	50	60	70
5	50	5	50	60	70	y_{t+1}
6	60	6	60	70	y_{t+1}	y_{t+2}
7	70	7	70	y_{t+1}	y_{t+2}	y_{t+3}

Pada tabel 1 digambarkan ilustrasi mengenai perubahan struktur data *time series* menjadi struktur data *supervised learning* yang digunakan untuk proses *training model* pada model ANN.

2.3 Statistical Learning

Statistical learning mengacu pada seperangkat alat untuk pemodelan dan pemahaman kumpulan data yang kompleks. *Statistical learning* adalah ranah statistika dan bercampur dengan pengembangan ilmu komputer secara paralel, khususnya *machine learning*. Bidang ini berisi banyak metode seperti lasso dan sparse, regresi, klasifikasi, *regression tree* dan *support vector machines* (James, G., dkk., 2014). Perkembangan *big data* dan *statistical learning* menjadi bidang yang sangat populer terutama pada ranah saintifik, pemasaran, keuangan dan juga bisnis. Terapan dari *statistical learning* kini mulai sering digunakan, sehingga individu yang memiliki keterampilan *statistical learning* memiliki peluang kerja yang lebih tinggi karena banyak dicari oleh perusahaan. Ide utama dalam pembelajaran statistik adalah membangun model yang dapat menarik kesimpulan dari data dan membuat prediksi dari data yang ada (James, G., 2014).

Statistical learning berperan penting dalam bidang keilmuan, keuangan dan industri. Beberapa contoh mengenai penggunaan *statistical learning* adalah sebagai berikut :

1. Untuk memprediksi apakah seorang pasien serangan jantung yang sedang dirawat di rumah sakit akan kembali mengalami serangan jantung
2. Untuk memprediksi harga dari sebuah saham dalam beberapa waktu kedepan
3. Untuk mengestimasi kadar gula darah dari seorang pasien diabetes dengan menggunakan spektrum inframerah
4. Untuk mengidentifikasi faktor risiko dari kanker prostat berdasarkan variable klinis dan demografis.

Model statistik adalah model yang mendefinisikan hubungan antara variabel terikat dan variabel bebas. Model statistik adalah kombinasi kesimpulan berdasarkan data yang dikumpulkan dan pemahaman populasi yang digunakan untuk memprediksi informasi dalam bentuk yang ideal. Contoh sederhana dari model statistik adalah $y = mx + c + \epsilon$ dimana m merepresentasikan gradien, c adalah intersep dan ϵ adalah bias atau galat. Pada *statistical learning*, terdapat validasi model digunakan untuk menilai *overfitting* dan *underfitting* data. Langkah untuk melakukan validasi model adalah:

1. Pisahkan data menjadi dua bagian, data pelatihan dan data pengujian (antara 60/40 atau 70/30).
2. Gunakan porsi yang lebih besar (data pelatihan) untuk melatih model
3. Gunakan porsi yang lebih kecil (pengujian data) untuk menguji model. Data ini tidak digunakan untuk melatih model, sehingga akan menjadi data baru bagi model untuk membangun prediksi.
4. Model yang telah dilatih dengan baik dari data pelatihan, maka model tersebut akan berkinerja baik dengan data pelatihan dan data pengujian. Untuk menentukan seberapa baik kinerja model pada kedua kumpulan data, dapat dihitung skor akurasi untuk masing-masing. Model dikatakan *over-fitting* jika data pelatihan memiliki nilai akurasi yang jauh lebih tinggi daripada data pengujian.

2.4 *Machine Learning* (Pembelajaran Mesin)

Machine Learning merupakan salah satu cabang dari ilmu kecerdasan buatan, khususnya mempelajari tentang bagaimana komputer mampu mempelajari pola data sehingga dapat meningkatkan kecerdasannya. Teknologi *machine learning* (ML) merupakan teknologi yang dikembangkan agar komputer bisa belajar dengan sendirinya tanpa arahan dari penggunanya (Sihombing dan Arsani, 2021). *Machine learning* adalah kemampuan komputer untuk melakukan pembelajaran tanpa harus menjelaskan atau melakukan program secara eksplisit kepada komputer (Arthur, 1959). Komputer mampu untuk melakukan proses pembelajaran dari pengalaman atau data terhadap masalah yang dihadapinya dan mengalami peningkatan kinerja. Ciri khas dari *machine learning* adalah adanya proses pembelajaran atau training dan pelatihan (Mitchell, T., 1997).

Machine learning memiliki fokus pada pengembangan sebuah sistem yang mampu belajar secara mandiri untuk memutuskan sesuatu tanpa harus berulang kali diprogram oleh manusia. Metode tersebut menciptakan mesin yang bisa menemukan aturan untuk perilaku optimal dalam pengambilan keputusan, serta dapat beradaptasi dengan perubahan yang terjadi. Mesin melakukan analisis dari kumpulan data yang besar untuk menemukan pola tertentu pada data.

Machine learning mempunyai 3 teknik atau algoritma pembelajaran yaitu:

1. *Supervised learning*

Supervised learning merupakan algoritma *machine learning* yang menggunakan dataset yang dikenal (*training dataset*) untuk membuat prediksi dan klasifikasi. *Output* pada *supervised learning* telah ditentukan sebelumnya dan proses pembelajaran akan berhenti ketika algoritma telah mencapai hasil yang diinginkan. Teknik yang digunakan oleh *supervised learning* adalah metode klasifikasi dimana kumpulan data sepenuhnya diberikan label untuk mengklasifikasikan kelas yang tidak dikenal (Roihan, dkk., 2020).

2. *Unsupervised learning*

Unsupervised learning merupakan algoritma pembelajaran yang tidak melibatkan target atau semua variabel yang digunakan dalam analisis digunakan sebagai *input*. Teknik ini cocok untuk *clustering* dan *association mining*. Metode *unsupervised learning* yang paling umum adalah analisis *cluster* yang digunakan pada analisa data untuk mencari pola-pola tersembunyi atau pengelompokkan dalam data (Alloghani, dkk 2019).

3. *Semi supervised learning*

Algoritma ini berada di antara algoritma *supervised* dan *unsupervised learning*. Cara kerja algoritma ini adalah dengan menggunakan teknik *unsupervised learning* untuk menemukan dan mempelajari struktur dalam variabel *input*. Sistem menggunakan algoritma *supervised learning* untuk membuat prediksi terbaik dari data tak berlabel dan memasukkan kembali data tersebut ke algoritma *supervised learning* sebagai data latih lalu menggunakan model tersebut untuk membuat prediksi baru dari data *input* baru.

2.5 Autoregressive Integrated Moving Average (ARIMA)

ARIMA adalah singkatan dari *Autoregressive Integrated Moving Average*. Model ARIMA adalah gabungan dari model peramalan time series *Auto Regressive* (AR) dan *Moving Average* (MA). Metode ini secara murni melakukan prediksi hanya berdasarkan data-data historis yang ada. Tujuan dari pemodelan ARIMA adalah menentukan hubungan statistik yang baik antar variabel yang diramal dengan nilai historis variabel tersebut sehingga peramalan dapat dilakukan dengan model tersebut. Meskipun ARIMA merupakan metode peramalan yang cukup fleksibel (mengikuti pola data) dalam merepresentasikan berbagai tipe data *time series* baik model AR, MA maupun *Auto Regressive Moving Average* (ARMA), terdapat batasan yakni asumsi linearitas model (Sari, V., 2016).

ARIMA merupakan model gabungan dari AR dan MA yang *difference* (Rumagit dan N., 2013). Box dan Jenkins mengembangkan pendekatan praktis untuk

membangun model ARIMA yang memiliki dasar pada analisis deret waktu dan aplikasi peramalan. Model Box-Jenkins meliputi model *non seasonal* (non-musiman) dan *seasonal* (musiman). Model *non seasonal* yang merupakan model stasioner terdiri dari AR(p), MA(q) dan ARMA(p,q), sedangkan model ARIMA (p,d,q) merupakan bentuk model non stasioner (Zhang, 2001). Berikut merupakan bentuk umum dari model AR, MA, ARMA dan ARIMA menurut Rumagit dan N. (2013):

1. Model *Auto Regressive* (Model AR)

$$Y_t = B_1 Y_{t-1} + \dots + B_p Y_{t-p} + e_t \quad (2.3)$$

dimana :

- Y_t : variabel dependen
 Y_{t-1}, Y_{t-p} : variabel Independen atau nilai data lampau
 B_1, B_p : koefisien regresi
 e_t : residual pada period ke - t

2. Model *Moving Average* (MA)

$$Y_t = e_t - W_1 e_{t-1} - \dots - W_q e_{t-q} \quad (2.4)$$

dimana :

- Y_t : variabel dependen
 W_1, W_q : bobot
 e_t : residual atau *error*
 e_{t-1}, e_{t-q} : nilai residual sebelumnya

3. *Autoregressive Moving Average* (ARMA)

$$Y_t = B_1 Y_{t-1} + \dots + B_p Y_{t-p} + e_t + W_1 e_{t-1} - \dots - W_q e_{t-q} \quad (2.5)$$

dimana :

- Y_t : variabel dependen
 Y_{t-1}, Y_{t-p} : variabel Independen atau nilai data lampau
 B_1, B_p : koefisien regresi
 W_1, W_q : bobot
 e_t : residual atau *error*

e_{t-1}, e_{t-q} : nilai residual sebelumnya

4. *Autoregressive Integrated Moving Average (ARIMA)*

Apabila nonstasioneritas ditambahkan pada campuran proses ARMA, maka model umum ARIMA (p, d, q) terpenuhi. Persamaan untuk model umum dari model ini adalah sebagai berikut :

$$Y_t = B_1 Y_{t-1} + \dots + B_p Y_{t-p} + e_t + W_1 e_{t-1} - \dots - W_q e_{t-q} \quad (2.6)$$

dimana :

Y_t : variabel dependen

Y_{t-1}, Y_{t-p} : variabel Independen atau nilai data lampau

B_1, B_p : koefisien regresi

W_1, W_q : bobot

e_t : residual atau *error*

e_{t-1}, e_{t-q} : nilai residual sebelumnya

2.6 *Artificial Neural Network (ANN)*

Jaringan saraf tiruan (JST) atau *artificial neural network* adalah salah satu model yang mampu mendekati berbagai pola nonlinier dalam data. JST adalah kerangka kerja komputasi yang fleksibel untuk memodelkan berbagai masalah nonlinier (Zhang, 2001). JST merupakan metode umum dan praktis untuk pembelajaran nilai *real*, nilai diskrit, dan nilai vektor dari contoh data. Algoritma seperti *backpropagation* menggunakan penurunan gradien untuk mengoptimalkan parameter jaringan menjadi yang terbaik. Pembelajaran JST kokoh terhadap kesalahan dalam pelatihan data dan telah berhasil diterapkan pada masalah seperti menafsirkan bentuk visual, pengenalan suara, dan mempelajari strategi kontrol robot (Mitchel, T., 1997). Studi mengenai jaringan saraf tiruan (JST) telah terinspirasi sebagian oleh pengamatan bahwa sistem pembelajaran biologis dibangun dari jaringan yang sangat kompleks dari neuron yang saling berhubungan (Mitchel, T., 1997). *Artificial neural networks*

(ANN) adalah teknik pembelajaran mesin yang terinspirasi oleh jaringan saraf biologis di otak manusia. Penentuan jumlah lapisan dan jumlah neuron di lapisan tersembunyi dan koneksi di antara neuron tersebut adalah hal yang penting. Neuron mempunyai karakteristik yang sama dalam ANN, terdiri dalam kelompok-kelompok yang disebut layer. Neuron dalam satu *layer* terhubung dalam *layer* lainnya yang berdekatan. Hubungan antar neuron yang berdekatan direpresentasikan dalam kekuatan hubungan atau bobot (Dharma dan Ardhana, 2011).

Jaringan saraf tiruan tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*) yang didasarkan atas asumsi sebagai berikut (Rumagit, 2013):

1. Pemrosesan informasi terjadi pada elemen sederhana yang disebut neuron.
2. Sinyal mengalir di antara sel saraf/neuron melalui suatu sambungan penghubung.
3. Setiap sambungan penghubung memiliki bobot yang bersesuaian. Bobot ini digunakan untuk menggandakan atau mengalikan isyarat yang dikirim melaluinya.

Komponen-komponen yang terdapat di dalam jaringan saraf tiruan adalah sebagai berikut:

a. Neuron Tiruan (*Artificial Neuron*)

ANN disusun oleh unit dasar yang disebut dengan neuron tiruan yang merupakan elemen pemrosesan dalam jaringan, dimana semua proses perhitungan dilakukan disini.

b. Lapisan (*Layer*)

ANN disusun oleh kumpulan neuron yang berhubungan dan dikelompokkan pada layer-layer. Dalam ANN terdapat tiga layer diantaranya: *input layer*, *hidden layer*, dan *output layer*.

c. Masukan (*Input*)


ANN dapat memproses data yang memiliki masukan berjenis numerik. Sehingga apabila masalah melibatkan data kualitatif seperti grafik, gambar, sinyal suara dan data tersebut akan diubah ke dalam data *numeric* yang ekuivalen sebelum diproses oleh ANN.

d. Keluaran (*Output*)

Keluaran dari ANN adalah berupa pemecahan terhadap masalah yang berupa data numerik.

e. Bobot (*Weight*)

Bobot adalah salah satu parameter yang penting untuk diperhatikan dalam jaringan syaraf tiruan. Nilai awal bobot ditentukan secara acak pada awal proses dan kemudian dilakukan penyesuaian nilai bobot untuk meminimalkan galat. Bobot dari sebuah ANN berupa deretan angka yang sangat penting untuk mengoptimalkan dan memungkinkan sebuah sistem menerjemahkan data masukan secara benar dan menghasilkan sebuah keluaran yang diinginkan.



Gambar 1. Struktur ANN

(sumber: <https://towardsdatascience.com/applied-deep-learning-part-1-artificial-neural-networks-d7834f67a4f6>)

Berdasarkan Gambar 1, bagian yang berwarna kuning merupakan *layer input* dari ANN. Lapisan tersebut diisi dengan informasi yang sudah dimiliki oleh peneliti. Bagian yang berwarna biru dan hijau adalah *hidden layer* yang berisi fungsi yang memproses data *input*. Bagian yang berwarna merah adalah *output* yang merupakan tempat dari data yang sudah diproses. Setiap informasi akan melalui garis penghubung yang akan disesuaikan dengan nilai bobot dan bias tertentu.

2.6.1 Arsitektur Jaringan

Arsitektur jaringan saraf tiruan merupakan susunan komponen lapisan (*layer*) dan neuron yang terdapat pada lapisan masukan, lapisan tersembunyi dan lapisan keluaran yang dihubungkan dengan bobot serta fungsi aktivasi sehingga menciptakan suatu jaringan saraf tiruan.

1. *Single Layer Perceptron*

Single layer perceptron merupakan salah satu jaringan *neural network* yang terdiri dari lapisan *input* dan *output*. Lapisan masukan adalah lapisan yang menerima masukan dari jaringan luar dan kemudian didistribusikan ke semua bagian neuron pada lapisan keluaran. *Single layer perceptron* adalah bentuk arsitektur ANN yang paling sederhana.

2. *Multi Layer Perceptron*

Multi layer perceptron atau yang dikenal dengan ANN adalah penembangan arsitektur jaringan ANN dengan menggunakan penambahan lapisan tersembunyi atau biasa disebut dengan *hidden layer*. *Hidden layer* ini terletak di antara lapisan masukan dan lapisan keluaran pada arsitektur jaringan ANN.

2.6.2 Nodes pada *hidden layer*

Jumlah nodes pada *hidden layer* memiliki peran penting terhadap arsitektur jaringan saraf tiruan. Menggunakan jumlah *nodes* yang terlalu sedikit dapat menyebabkan *underfitting* pada model. Menggunakan jumlah nodes yang terlalu banyak dapat menyebabkan model terlalu kompleks sehingga menyebabkan *overfitting* (Kumar, P., 2015).

Terdapat 3 aturan yang umum digunakan dalam penentuan jumlah *nodes* pada *hidden layer* jaringan saraf tiruan yang dinamakan aturan heaton, diantaranya (Kumar, P., 2015) :

- 1) Jumlah *nodes* pada *hidden layer* berada diantara jumlah *nodes* pada input dan output
- 2) Jumlah *nodes* pada *hidden layer* adalah $\frac{2}{3}$ dari jumlah *nodes* pada *input*, kemudian dijumlahkan dengan *nodes* pada *output*
- 3) Jumlah *nodes* pada *hidden layer* disarankan kurang dari 2 kali jumlah *nodes* pada *input layer*

2.6.3 Fungsi Aktivasi

Fungsi aktivasi disebut juga sebagai fungsi transfer. Fungsi aktivasi menentukan hubungan antara *input* dan *output* dari suatu *node* dan suatu jaringan saraf tiruan. Fungsi Aktivasi menentukan tingkat *nonlinearity* yang menjadi fokus utama dalam pengaplikasian dari ANN (Zhang, dkk., 1998).

Menurut Zhang, dkk. pada tahun 1998, penerapan penggunaan fungsi aktivasi, terdapat beberapa fungsi yang umum digunakan dalam ANN, diantaranya :

1.) Fungsi sigmoid (fungsi *logistic*)

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

di mana :

e : bilangan euler

x : data

2.) Fungsi tan hiperbolik

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2.8)$$

di mana :

e : bilangan euler

x : data

3.) Fungsi sinus atau cosinus

$$\begin{aligned} f(x) &= \sin(x) \\ f(x) &= \cos(x) \end{aligned} \quad (2.9)$$

di mana :

x : data

4.) Fungsi linear

$$f(x) = x \quad (2.10)$$

di mana :

x : data

5.) Fungsi ReLU

$$f(x) = \max(0, x) \quad (2.11)$$

di mana :

x : data

Penggunaan fungsi aktivasi sigmoid pada *nodes output* merupakan hal yang baik untuk digunakan dalam kasus klasifikasi. Namun, untuk kasus data deret waktu disarankan untuk menggunakan fungsi aktivasi linear (Zhang, dkk., 1998)

2.6.4 Dropout

Dropout adalah suatu teknik untuk mencegah terjadinya *overfitting* dalam proses pembelajaran mesin. istilah *dropout* merujuk kepada penghentian penggunaan *nodes* secara sementara. Nilai *dropout* sebesar 20% hingga 50% dari jumlah *nodes* merupakan hal yang optimal untuk mencegah terjadinya *overfitting* (Srivastava, dkk., 2014).

2.6.5 Adaptive Moment Estimation

Adaptive moment estimation atau Adam merupakan algoritma optimasi yang dikembangkan dan merupakan salah satu *optimization function* dalam Python dengan memanfaatkan kelebihan dari algoritma *Adaptive Gradient* (AdaGrad) yang bekerja dengan baik dan *Root Mean Square Propagation* (RMSProp) yang bekerja dengan baik secara *on-line* dan non pengaturan-stasioner. Adam tidak hanya mengadaptasi tingkat pembelajaran parameter berdasarkan rata-rata pertama (*mean*) seperti dalam RMSProp, namun Adam juga menggunakan rata-rata kedua dari gradien (*varians uncentered*). Algoritma menghitung rata-rata pergerakan eksponensial dari gradien dan gradien kuadratnya, dan parameter β_1 dan β_2 mengontrol tingkat peluruhan rata-rata pergerakan (Aldi, dkk., 2018).

Beberapa keuntungan Adam adalah bahwa besarnya pembaruan parameter tidak sama dengan penyekalaan gradien, ukurannya dibatasi oleh *hyperparameter* step-size, tidak memerlukan alat tulis stasioner. *Adaptive Moment Estimation* adalah metode yang menghitung *adaptive learning rate* untuk setiap parameter. Nilai parameter yang direkomendasikan adalah $\beta_1 = 0.9$, $\beta_2 = 0.999$, dan $\epsilon = 10^{-8}$ dengan

$\beta_1 = \beta_2 =$ tingkat penurunan eksponensial dan $\epsilon =$ nilai epsilon untuk update parameter (Kingma dan Ba, 2015)

2.7 ARIMA - ANN (*Hybrid*)

Metode *hybrid* merupakan perkembangan dalam peramalan data *time series* dengan menggabungkan dua metode tunggal, salah satunya penggabungan ARIMA dan ANN. Pengembangan metode *hybrid* dilakukan dengan beberapa alasan sebagai berikut (Zhang, 2001):

1. Meningkatkan efisiensi dalam tahapan analisis peramalan deret waktu. Sulit untuk menentukan apakah deret waktu mengandung pola linier ataupun nonlinier membuat peneliti menggunakan lebih dari satu metode untuk dilakukan perbandingan. Dengan melakukan kombinasi *hybrid*, permasalahan seleksi model dapat diminimalisir.
2. Kasus *time series* yang murni linier ataupun nonlinier sangat jarang terjadi. Pola data lebih sering mengandung campuran keduanya. Jika kasus seperti ini yang dihadapi, maka metode tunggal dinilai kurang efektif karena tidak dapat menangkap pola campuran.
3. Tidak ada suatu metode tunggal yang terbaik dalam setiap situasi. Pola data yang kompleks dalam kasus nyata menjadi alasan sebuah metode tunggal tidak dapat menangkap berbagai macam pola yang terkandung dalam data dengan baik.

Model *hybrid* adalah suatu metode kombinasi dari dua model atau lebih dalam suatu sistem. Model ARIMA dan ANN merupakan model *hybrid* untuk mengatasi masalah linear dan non linear (Zhang, 2001). Secara umum, kombinasi dari model *time series* yang memiliki struktur autokorelasi linier dan nonlinier dapat dituliskan:

$$y_t = L_t + N_t \quad (2.12)$$

di mana :

- y_t : nilai aktual ke t
- L_t : komponen linear ke t
- N_t : komponen nonlinear ke t
- t : indeks waktu

Dua komponen di atas didapat dari ramalan (estimasi) data. Pertama, hasil ramalan data *time series* dengan model ARIMA digunakan sebagai komponen linear. Kemudian, residual dari model linear sebagai komponen nonlinear. Misal, e_t sebagai residual pada saat t pada model linier, maka :

$$e_t = y_t - L'_t \quad (2.13)$$

di mana :

- y_t : Nilai Aktual ke t
- L'_t : Komponen linear ke t
- e_t : nilai residual ke t
- t : indeks waktu

Komponen linear L'_t merupakan nilai prediksi ARIMA pada waktu t . Sebuah model linier tidak akan terpenuhi apabila masih terdapat struktur korelasi linier pada residual. Tidak ada diagnostik statistik untuk kasus hubungan autokorelasi nonlinear. Pemodelan residual menggunakan ANN dapat menemukan hubungan nonlinear pada data *time series*. Pemodelan residual menggunakan ANN dengan unit *input* sebanyak n dapat dituliskan sebagai berikut:

$$e_t = f(e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n)} + \varepsilon_t) \quad (2.14)$$

di mana :

- e_t : nilai residual ke t

f : fungsi non linear dari ANN
 t : indeks waktu

Fungsi f merupakan fungsi nonlinier yang dijelaskan oleh ANN dan ε_t adalah error yang acak ke t . Persamaan diatas ditulis sebagai N'_t . Sehingga, peramalan *hybrid* merupakan kombinasi dari dua komponen yang kemudian ditulis sebagai berikut:

$$y'_t = L'_t + N'_t \quad (2.15)$$

di mana :

y'_t : prediksi dari model *hybrid* ke t
 L'_t : prediksi komponen linear dari ANN ke t
 N'_t : prediksi komponen residual dari ANN ke t
 t : indeks waktu

Langkah dari metode *hybrid* terdiri dari dua tahap. Langkah pertama, model ARIMA digunakan untuk memprediksi bagian linear. Langkah kedua, model ANN dibangun untuk memodelkan bagian linear serta residual dari model ARIMA. Karena model ARIMA tidak dapat menangkap struktur nonlinier dari data, model residual akan memiliki informasi tentang nonlinearitas dari data. Hasil dari ANN dapat digunakan untuk meramalkan error untuk model ARIMA

Langkah utama pemodelan *Hybrid* ARIMA – ANN adalah sebagai berikut:

1. Melakukan dekomposisi data *time series* menjadi komponen linear dan non linear
2. Memodelkan setiap komponen dengan menggunakan ARIMA dan ANN. Komponen linear dimodelkan dengan ARIMA. Komponen linear dari ARIMA dan komponen non linear kemudian dimodelkan dengan ANN.
3. Melakukan penggabungan antara kedua model

2.8 Akurasi

Akurasi adalah parameter yang digunakan untuk mengukur seberapa baik model yang dibuat. Terdapat beberapa parameter evaluasi yang bisa digunakan, diantaranya adalah *mean square error* (MSE) dan *mean absolute percentage error* (MAPE). MAPE dihitung menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata pada periode itu. Lalu, merata-rata kesalahan persentase absolut tersebut. Pendekatan yang dilakukan ini berfungsi untuk saat ukuran atau besar variable prediksi itu penting dalam mengevaluasi ketepatan ramalan. MAPE juga mengindikasikan seberapa besar kesalahan dalam memprediksi yang dibandingkan dengan nilai aktual. Model prediksi dapat dikatakan baik apabila memiliki nilai MAPE yang rendah (Chang, dkk., 2007).

$$MAPE = \sum_{i=1}^n \frac{|Actual_i - Predicted_i|}{Actual_i} \times 100\% \quad (2.16)$$

di mana :

$Actual_i$: data Aktual ke i

$Predicted_i$: data hasil prediksi ke i

n : banyaknya periode prediksi

i : indeks waktu

Tabel 2. Kriteria nilai MAPE

No	MAPE	Penjelasan Nilai
1	<10	Sangat Baik
2	10 – 20	Baik
3	20 – 50	Sedang
4	> 50	Buruk

Mean Squared Error adalah rata-rata dari kesalahan prediksi dikuadratkan. *Mean Squared Error* (MSE) adalah metode lain untuk mengevaluasi metode prediksi.

Nilai MSE yang rendah atau mendekati nol menunjukkan bahwa hasil prediksi semakin sesuai dengan data aktual. Semakin rendah nilai MSE, maka semakin baik metode tersebut digunakan untuk melakukan peramalan.

$$MSE = \frac{\sum_{i=1}^n (X_i - F_i)^2}{n} \quad (2.17)$$

di mana :

- X_i : data aktual ke i
- F_i : data prediksi ke i
- n : banyaknya periode prediksi
- i : indeks waktu

Root Mean Squared Error (RMSE) adalah akar dari rata-rata kesalahan prediksi dikuadratkan. RMSE merupakan besarnya tingkat kesalahan hasil prediksi. Hasil prediksi semakin baik apabila nilai RMSE semakin mendekati nilai nol.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - F_i)^2}{n}} \quad (2.18)$$

di mana :

- X_i : data aktual ke i
- F_i : data prediksi ke i
- n : banyaknya periode prediksi
- i : indeks waktu

2.9 Polygon Matic

Polygon Matic diluncurkan pada bulan Oktober 2017. Polygon awalnya bernama Matic Network, dibuat pada tahun 2017. Matic dibuat oleh beberapa developer Ethereum, yaitu Jaynti Kanani, Sandeep Nailwal, Anurag Arjun, dan Mihailo

Bjelic. Matic diciptakan karena para pendirinya melihat masalah skalabilitas Ethereum dimana peningkatan kepadatan jaringan menyebabkan biaya transaksi yang tinggi dan proses transaksi yang lambat. Matic memberikan solusi skalabilitas lapisan 2 untuk masalah itu.

Polygon sering disebut sebagai "*Ethereum's Internet of blockchain*" karena menciptakan ekosistem multi-rantai yang dapat dioperasikan dengan Ethereum. Hal ini sangat merepotkan bagi pengembang *Decentralized Finance (DeFi)* atau keuangan terdesentralisasi serta pengembang *Decentralized Apps (DApps)* atau aplikasi terdesentralisasi karena pengguna harus mengeluarkan lebih banyak bahan bakar untuk menggunakan aplikasi tersebut. Token Matic mengalami peningkatan pesat sejak awal tahun 2021, terkait dengan perubahan nama jaringan Matic menjadi Polygon. Token Matic serupa dengan mata uang kripto pada umumnya karena mengalami volatilitas tinggi. Polygon masih dalam tahap pengembangan, namun terdapat lebih dari 350 aplikasi yang berproses di dalam jaringannya. Proyek *DeFi* merupakan proyek populer seperti Aave dan SushiSwap yang mulai menyertakan jaringan Polygon dalam pelayanan (Santosa, A.,B., 2021).

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2021/2022, bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan merupakan data harian yang tersedia pada situs Kaggle dengan link <https://www.kaggle.com/datasets/kaushiksuresh147/maticpolygon-cryptocurrency-historical-dataset>. Data yang tersedia memiliki 5 variabel yaitu *open*, *high*, *low*, *close* dan *volume*. *Open* merupakan harga pembukaan dari mata uang kripto, *High* merupakan harga tertinggi dari mata uang kripto, *low* merupakan harga terendah dari mata uang kripto, *close* merupakan harga penutupan dari mata uang kripto, *volume* merupakan banyaknya volume transaksi yang terjadi dari mata uang kripto. Data yang digunakan pada penelitian ini adalah data historis dari harga penutupan (*close*) mata uang kripto Matic yang diambil selama hampir 1 tahun dan terdapat 351 data. Periode waktu dari data yang digunakan yaitu dari bulan Februari 2021 hingga Februari 2022. Data harga penutupan (*close*) yang digunakan berkaitan dengan metode ARIMA yang merupakan metode univariat sehingga hanya satu variabel yang digunakan. Data diambil setiap 24 jam sekali sehingga terdapat 351 data. Data dapat diunduh secara langsung dalam bentuk CSV.

Tabel 3. Data mata uang kripto Matic

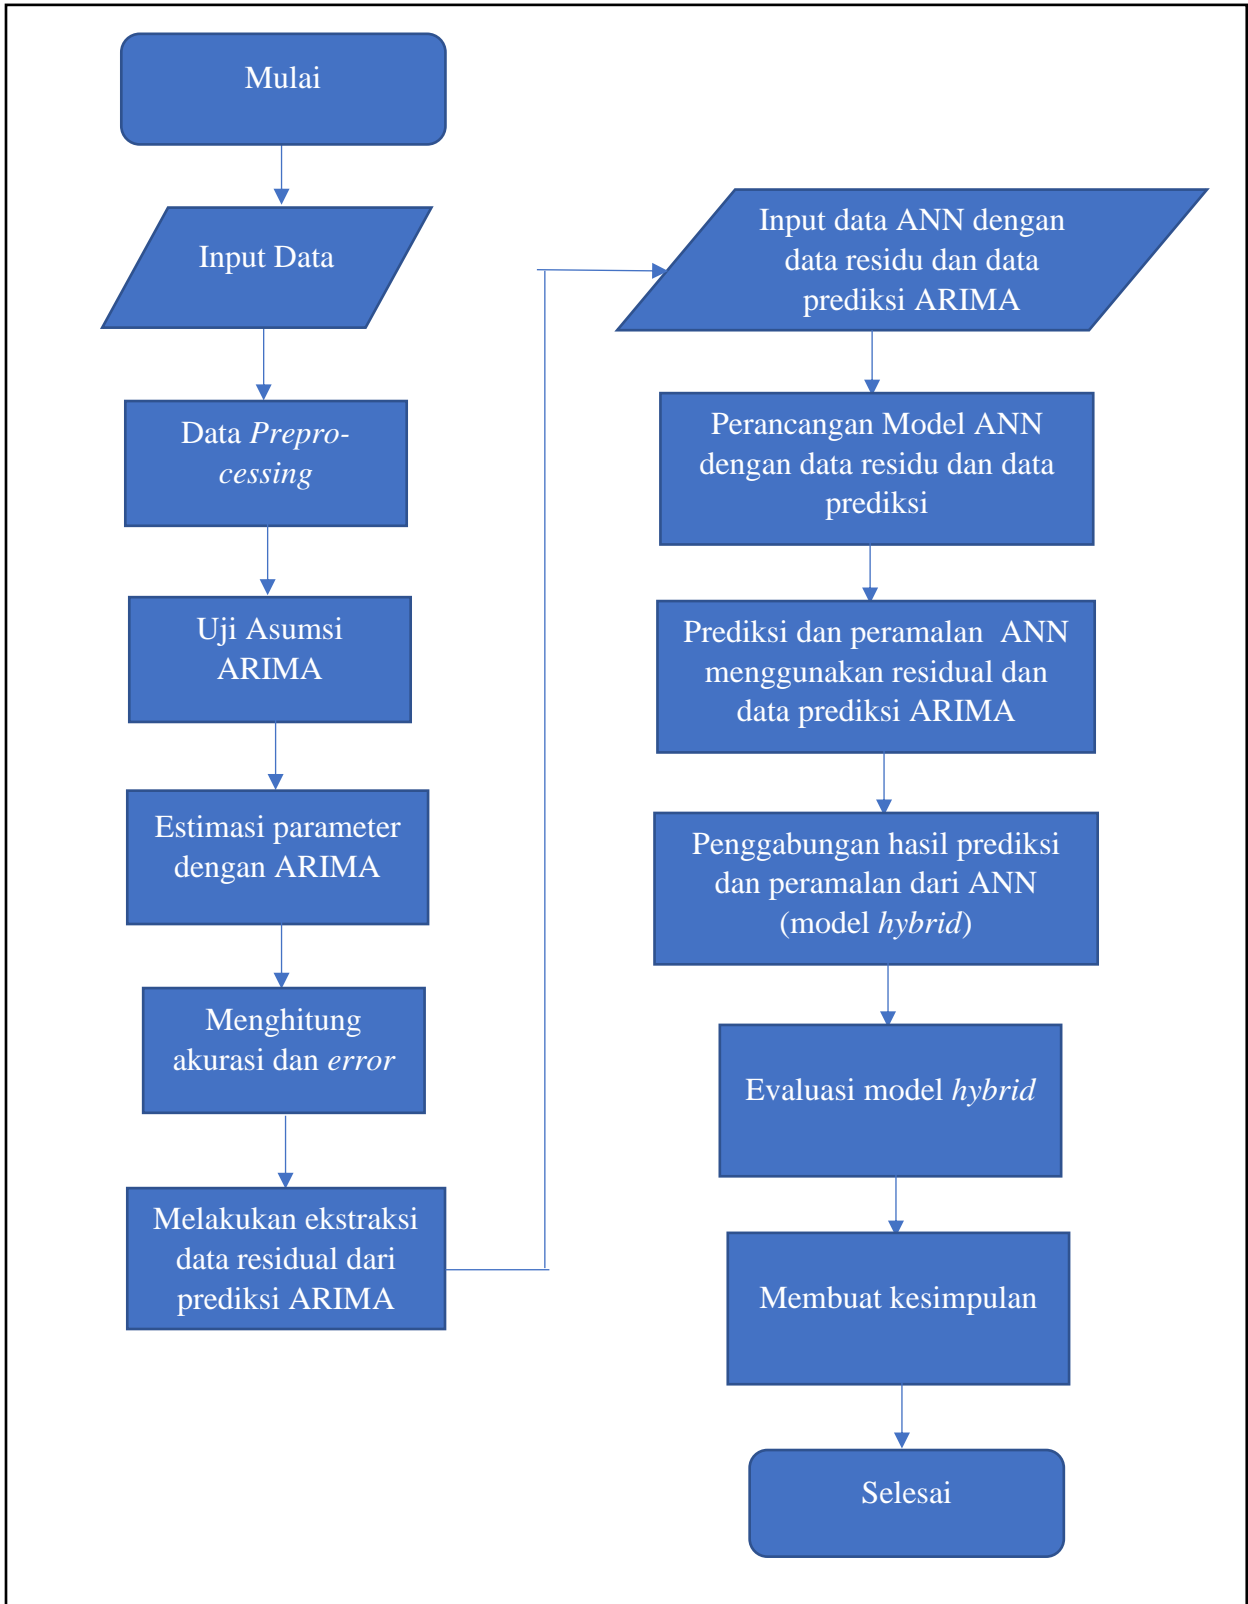
<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>
16/02/2021	0.107	0.115	0.101	0.109	496433632
17/02/2021	0.109	0.119	0.096	0.112	544802304
18/02/2021	0.112	0.134	0.112	0.122	613168000
19/02/2021	0.122	0.165	0.119	0.154	776462464

3.3 Metode Penelitian

Berikut merupakan alur dari pengerjaan metode *hybrid* ARIMA – ANN :

1. Melakukan studi literatur mengenai proses model *hybrid* dari ARIMA – ANN yang diambil dari buku, jurnal serta dibantu oleh narasumber yang memahami model *hybrid* ARIMA – ANN.
2. Mengumpulkan data yang digunakan untuk proses peramalan dengan metode *hybrid* ARIMA – ANN.
3. Melakukan *pre-processing* data agar dapat diproses dengan menggunakan ARIMA. Data yang digunakan adalah data harga penutupan dari mata uang kripto Matic sebanyak 351 data dan merupakan data historis dengan periode harian.
4. Melakukan pembentukan model ARIMA yang digunakan untuk peramalan data mata uang kripto Matic. Tahapan dilakukan dengan melakukan identifikasi orde p, d dan q untuk model ARIMA yang digunakan untuk melakukan prediksi.
5. Berdasarkan Model ARIMA yang telah ada, kemudian dilakukan untuk memprediksi data mata uang kripto Matic.
6. Melakukan ekstraksi data residual yang merupakan selisih antara data prediksi ARIMA dengan data aktual dari mata uang kripto Matic.
7. Data prediksi dan data residual dari ARIMA digunakan sebagai input untuk diolah dengan menggunakan ANN.
8. Melakukan *splitting* untuk kedua data dengan skema 70% *training*, 30% *testing* dan skema 60% *training*, 40% *testing*.

9. Membuat dua model utama dengan menggunakan ANN sebagai landasan dalam melakukan proses *hybrid*. Model utama pertama merupakan model yang digunakan untuk memprediksi data prediksi ARIMA. Model utama kedua merupakan model yang digunakan untuk memprediksi data residual dari ARIMA.
10. Melakukan pembentukan model ANN dengan menggunakan *Python* sebagai *tools* untuk mengolah data.
11. Penentuan parameter model ANN untuk data prediksi dari ARIMA dan data residual dari ARIMA, dilakukan dengan menggunakan *hyperparameter tuning* untuk menentukan parameter terbaik.
12. Melakukan prediksi dan peramalan dengan model ANN pertama menggunakan data prediksi dari ARIMA.
13. Melakukan prediksi dan peramalan dengan model ANN kedua menggunakan data residual dari ARIMA.
14. Menggabungkan hasil prediksi dan peramalan dari kedua model utama ANN dengan proses penjumlahan.
15. Hasil dari penggabungan dari data prediksi dan data residual merupakan model *hybrid* ARIMA – ANN.



Gambar 2. *Workflow* ARIMA - ANN

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Metode ARIMA-ANN dapat digunakan untuk melakukan peramalan terhadap mata uang kripto Matic dengan baik. Kesimpulan yang didapatkan selama proses pengerjaan penelitian peramalan mata uang kripto Matic dengan metode *hybrid* ARIMA – ANN adalah sebagai berikut :

1. Metode *hybrid* ARIMA – ANN adalah metode yang tergolong sangat baik untuk melakukan prediksi serta peramalan untuk data fluktuatif seperti data mata uang kripto Matic. Metode ini menghasilkan nilai MSE sebesar 0.05557, MAPE sebesar 0.08867 dan RMSE sebesar 0,2357.
2. Skema *splitting* data 70% *training* dan 30% *tesing* memiliki nilai evaluasi yang lebih baik dibandingkan dengan skema *splitting* data 60% *training* dan 40% *testing*.
3. Metode *hybrid* ARIMA_ANN dapat melakukan peramalan dengan baik dan mengikuti pola data *ter-update* dari mata uang kripto Matic terutama untuk model dengan skema *splitting* data 70% *training* dan 30% *testing*.

5.2 Saran

Saran yang dianjurkan untuk peneliti selanjutnya adalah dengan menggunakan data yang lebih banyak untuk melakukan analisis. Data yang lebih banyak dapat digunakan untuk melakukan *splitting* data dengan skema yang lebih bervariasi.

Penelitian selanjutnya dapat pula menggunakan metode *K-Fold* dalam proses *training* data. Penelitian selanjutnya disarankan pula untuk mencoba menggunakan variabel *open*, *high*, *low*, *volume* serta *close* secara simultan untuk melakukan prediksi serta peramalan. Terdapat pula berbagai macam teknik metode *hybrid* ARIMA-ANN yang dapat digunakan untuk penelitian selanjutnya, diantaranya proses *hybrid* ARIMA-ANN yang dicetuskan oleh Zhang, Khasei dan Bijari, Narendra Babu dan Eswara Reddy, NoLic *hybrid* ARIMA-ANN *method* dan sebagainya.

DAFTAR PUSTAKA

- Addinanto, H., 2018. *Determinan Penggunaan Mata Uang Kripto Di Indonesia*.
UII.
- Aldi, M. W., Jondri dan Aditsania, A., 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *e-Proceeding of Engineering*, Volume Vol.5, pp. 3548 - 3555.
- Alloghani, M., Al - Jumeily, D., Mustafina, J. dan Hussain, A., n.d. *A Systematic Review on Supervised and Unsupervised Machine Learning for Data Science*. In: *Supervised and Unsupervised Learning for Data Science*. s.l.:Springer, p. Chapter 1.
- Arthur, S., 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal*, 3(3), pp. 210-229.
- Chang, P. C., Wang, Y. W. dan Liu, C. H., 2007. The development of a weighted evolving fuzzy neural network for PCB sales forecasting. *Expert Systems with Applications*, Volume 32(1), pp. 86 - 96.
- Davies dan Benon, P., 2004. *Database Systems Third Edition*. 3rd Ed. Hampshire: Palgrave Macmillan.
- Dharma, S., Putera, A. dan Ardana, D. H., 2011. Artificial Neural Networks Untuk Pemodelan Curah Hujan - Limpasan Pada Daerah Aliran Sungai Di Pulau Bali. *Jurnal Bumi Lestari*, 11(1), pp. 9 - 22.
- Han, j. dan Kamber, M., 2006. *Data Mining : Concepts and Techniques*. 2nd ed. San Francisco: Morgan Kaufmann.
- Heizer, J. dan Render, B., 2015. *Manajemen Operasi : Manajemen Keberlangsungan dan Rantai Pasokan*. 11 ed. Jakarta: diterjemahkan : Salemba empat.

- James, G., Witten, D., Hastie, T. dan Tibshirani, R., 2014. *An Introduction to Statistical Learning with Applications in R*. New York: Springer Texts in Statistics.
- Johnson, j., 2021. Is Matic a Serious Rival to Ethereum?. *SSRN*.
- Kingma, D. P. dan Ba, J. L., 2015. ADAM: a method for stochastic optimization. s.l., *ICLR*.
- Kumar, P., 2015. FF Neural Network. *IJRDO - Journal of Computer Science and Engineering*, 1(12), pp. 49 - 58.
- Lucciana, P., 2017. *Peramalan Jumlah Penumpang Penerbangan di Terminal 1 Bandara Internasional Juanda menggunakan metode ARIMA BOX-JENKINS dan Hybrid ARIMA - ANN*, Surabaya: ITS.
- Machmudin, A. dan Brodjol, S. S. U., 2020. Peramalan Temperatur Udara di Kota Surabaya dengan menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni ITS*, 1(1), pp. 118 - 123.
- Mitchell, T., 1997. *Machine Learning*. s.l.:McGraw-Hill.
- Moghaddam, A. H., Moghaddam, M. H. dan Esfandyari, M., 2016. Stock market index prediction using Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*, Volume 21, pp. 89 - 93.
- Montgomery, D. C., Jennings, L. C. dan Kulahci, M., 2015. *Introduction to time series analysis and forecasting*. 2nd ed. New Jersey: John Wiley dan Sons.
- Noorsanti, R. C., Yulianton, H. dan Hadiono, K., 2018. Blockchain - Teknologi Mata Uang Kripto (Crypto Currency). s.l., *Prosiding SENDI_U*.
- Pramudiono, I., 2003. Pengantar Data Mining: Menambang Permata Pengetahuan di Gunung Data. *Kuliah Umum IlmuKomputer.Com*.
- Roihan, A., Sunarya, P. A. dan Rafika, A. S., 2020. Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. *IJCIT*, Volume 1, pp. 75 - 82.
- Rumagit, S. E. dan N, A. S., 2013. Prediksi Pemakaian Listrik Kelompok Tarif Menggunakan Jaringan Syaraf Tiruan dan ARIMA. *IJCCS*, Volume 7, pp. 189 - 198.
- Santosa, A. B., 2021. *pintu.co.id*. [Online]
Available at: <https://pintu.co.id/academy/post/apa-itu-cardano#sejarah-Matic>
[Accessed 18 January 2022].
- Santosa, B., 2007. *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.

- Sari, V., 2016. Model Hybrid ARIMA dan Neural Network untuk meramalkan data time series. *Median*, Volume 9, pp. 13 - 18.
- Sihombing, P. R. dan Arsani, A. M., 2021. Perbandingan Metode Machine Learning Dalam Klasifikasi Kemiskinan Di Indonesia Tahun 2018. *Jurnal Teknik Informatika*, Volume 2, pp. 51-56.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., dan Salakhutdinov, R., 2014. Dropout : A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research* , Volume 15, pp. 1929 - 1958.
- Ulumuddin, I., Sunardi dan Fadlil, A., 2020. Bitcoin Price Prediction Using Long Short Term Memory (LSTM). *Jurnal Mantik*, Volume 4, pp. 1090 - 1095.
- Zhang, G. P., 2001. Time series forecasting using a hybrid ARIMA and Neural Network Model. *Elsevier Neuro Computing*, pp. 159 - 175.
- Zhang, G., Patuwo, B. E. dan Hu, M. Y., 1998. Forecasting with artificial neural network. *Elsevier*, Volume 14, pp. 35-62.