

***HYBRID VECTOR AUTOREGRESSIVE (VAR) – LONG - SHORT TERM  
MEMORY (LSTM) DALAM PERAMALAN HARGA MATA UANG  
KRIPTO***

**(Skripsi)**

**Oleh**

**MIA FITRIANI**



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

## **ABSTRACT**

### **HYBRID VECTOR AUTOREGRESSIVE (VAR) – LONG SHORT TERM MEMORY (LSTM) IN CRYPTOCURRENCY PRICE FORECASTING**

**By**

**MIA FITRIANI**

Uncertainty about cryptocurrency prices is an important thing in making decisions, especially for investors. Vector Autoregressive (VAR) is a method that can be used to do forecasting, but it has shortcomings in overcoming non-linear patterns in data. Long Short Term Memory (LSTM) is a method that is able to capture non-linear patterns that cannot be overcome by the VAR method. In this study, the VAR-LSTM hybrid model was applied to cryptocurrency prices for 30 days, namely February to March 2022. The VAR-LSTM hybrid model consists of the first model built with VAR prediction data and the second model built with VAR residual data. The VAR-LSTM hybrid model with a scheme of 90% training data and 10% testing data produces the best forecasting model when compared to other methods and schemes based on the MAPE value obtained of 99.94% and the p-value of  $T^2$  Hotelling test is 0.7041.

**Keywords:** VAR, LSTM, Hybrid VAR-LSTM, Forecasting, Crypto Prices

## ABSTRAK

### ***HYBRID VECTOR AUTOREGRESSIVE (VAR) – LONG SHORT TERM MEMORY (LSTM) DALAM PERAMALAN HARGA MATA UANG KRIPTO***

Oleh

**MIA FITRIANI**

Peramalan mengenai harga mata uang kripto menjadi hal penting dalam pengambilan keputusan terutama bagi para investor. *Vector Autoregressive (VAR)* merupakan metode yang dapat digunakan untuk melakukan peramalan, namun memiliki kekurangan dalam mengatasi pola non linier dalam data. *Long Short Term Memory (LSTM)* merupakan metode yang mampu menangkap pola non linier yang tidak dapat diatasi oleh metode VAR. Model *hybrid VAR-LSTM* merupakan model yang diharapkan mampu melakukan peramalan dengan akurat. Dalam penelitian ini dilakukan penerapan model *hybrid VAR-LSTM* pada harga mata uang kripto selama 30 hari yaitu Februari sampai dengan Maret 2022. Model *hybrid VAR-LSTM* tersusun atas model pertama yang dibangun dengan data prediksi VAR dan model kedua yang dibangun dengan data residual VAR. Model *hybrid VAR-LSTM* dengan skema 90% data *training* dan 10% data *testing* menghasilkan model peramalan terbaik jika dibandingkan dengan metode dan skema lainnya berdasarkan nilai MAPE yang didapat sebesar 99,94% dan *p-value* uji  $T^2$  Hotelling sebesar 0,7041.

**Kata Kunci :** VAR, LSTM, *Hybrid VAR-LSTM*, Peramalan, Harga Kripto

***HYBRID VECTOR AUTOREGRESSIVE (VAR) – LONG - SHORT TERM  
MEMORY (LSTM) DALAM PERAMALAN HARGA MATA UANG  
KRIPTO***

Oleh

**MIA FITRIANI**

**Skripsi**

**Sebagai Salah Satu Syarat untuk Mencapai Gelar  
SARJANA MATEMATIKA**

**Pada**

**Jurusan Matematika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Lampung**



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

Judul Skripsi

***:HYBRID VECTOR UTOREGRESSIVE (VAR) -  
LONG SHORT TERM MEMORY (LSTM)  
DALAM PERAMALAN HARGA MATA UANG  
KRIPTO***

Nama Mahasiswa

**: Mia Fitriani**

Nomor Pokok Mahasiswa

**: 1917031004**

Program Studi

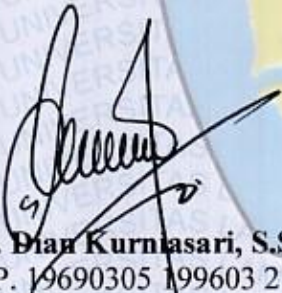
**: Matematika**

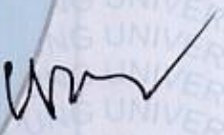
Fakultas

**: Matematika dan Ilmu Pengetahuan Alam**

**MENYETUJUI**

**1. Komisi Pembimbing**

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

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

**2. Ketua Jurusan Matematika**

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

**MENGESAHKAN**

1. Tim Penguji

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

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

Penguji  
Bukan Pembimbing: **Prof. Drs. Mustofa Usman, M.A., Ph.D.**

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

**Dr. Eng Heri Satria, S.Si., M. Si.**  
NIP 19711001 200501 1 002



Tanggal Lulus Ujian Skripsi : **11 Juli 2024**

## PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Mia Fitriani**

Nomor Pokok Mahasiswa : **1917031004**

Jurusan : **Matematika**

Judul Skripsi : ***HYBRID VECTOR UTOREGRESSIVE (VAR) –  
LONG SHORT TERM MEMORY (LSTM)  
DALAM PERAMALAN HARGA MATA UANG  
KRIPTO***

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

Bandar Lampung, 11 Juli 2024



Mia Fitriani  
NPM. 1917031004

## **RIWAYAT HIDUP**

Penulis bernama Mia Fitriani yang merupakan anak ketiga dari pasangan Bapak Oto Iskandar dan Ibu Supinawati. Penulis lahir di Mutar Alam pada tanggal 11 Mei 2001. Penulis menjalani pendidikan Sekolah Dasar (SD) hingga Sekolah Menengah Atas di Kabupaten Lampung Barat. Penulis menyelesaikan pendidikan dasar di SDN 1 Karang Agung dan lulus pada tahun 2013. Tahun 2016, penulis menyelesaikan Sekolah Menengah Pertama di SMPN 1 Way Tenong dan pada tahun 2019 penulis menyelesaikan pendidikan di SMAN 1 Way Tenong.

Pada tahun 2019, penulis melanjutkan pendidikan sebagai mahasiswa Jurusan Matematika di Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Penulis menjadi mahasiswa penerima bantuan biaya pendidikan BIDIKMISI. Selama menjadi mahasiswa, penulis bergabung di dalam Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) sebagai anggota Biro Kesekretariatan pada periode 2020 dan menjadi Sekretaris Biro Kesekretariatan pada periode 2021.

Pada bulan Januari hingga Februari tahun 2022, penulis melaksanakan Praktik Kerja Lapangan (PKL) di Dinas Komunikasi, Informatika dan Statistik (KOMINFOTIK) Provinsi Lampung. Kemudian, penulis melaksanakan Kuliah Kerja Nyata di Desa Sukarame, Kecamatan Talang Padang, Kabupaten Tanggamus pada bulan Juni hingga Agustus 2022.



## **PERSEMBAHAN**

### **Bismillahirrahmanirrahim**

Dengan penuh rasa syukur atas segala limpahan Rahmat dan Karunia dari Allah SWT., kupersembahkan karya sederhana ini untuk:

### **PAPA DAN MAMA**

Terima kasih atas segala cinta kasih, perjuangan, dan do'a yang telah papa dan mama limpahkan selama ini. Semoga setiap lelah dan untaian kata dari papa dan mama selalu menjadi penguat yang mengiringi setiap langkah. Tentu, karya sederhana ini tak sebanding dengan pengorbanan papa dan mama. Tapi percayalah, ini adalah awal dari mimpi besarku membanggakan kalian semua.

### **MTAK ITA DAN MTAK ANA**

Mbak, terima kasih sudah memberikan banyak pengalaman dan pelajaran berharga dalam hidupku. Terima kasih sudah menjadi rumah kedua, mendengarkan keluh dan kesah dalam setiap langkah dan masa sulit dalam perjalananku.

### **SYABIL DAN SYAQUILA**

Semoga kelak apa yang baik dalam perjalanan hidup Cicik, bisa menjadi pelajaran berharga dalam hidup kalian.

Seluruh keluarga dan sahabat yang dengan setia menemani di setiap proses perjalanan serta orang-orang yang sempat meragukanku.

**Almamater tercinta, Universitas Lampung.**

## KATA INSPIRASI

*“Dalam hidup ada hal yang datang dengan sendirinya, dan ada hal yang harus diperjuangkan dahulu untuk mendapatkannya.”*

*(Aisyah RA)*

*“Seorang pemenang tidak pernah menyerah, dan orang yang menyerah tidak pernah menang.”*

*(Aisyah RA)*

*“Ikhlaskan, maka lebih mudah untukmu melupakan apa yang tak mungkin kamu genggam”*

*(A. Shiddiq W.)*

*“Gadis terakhir orang tua, tetaplah berdiri tegak. Mereka menunggu pulangmu dengan senyum bahagia.”*

*(PENULIS)*

## SANWACANA

Alhamdulillah, puji syukur penulis panjatkan kehadirat Allah SWT. Karena atas rahmat dan karunia-Nya, penulis dapat menyelesaikan penulisan skripsi yang berjudul **“Hybrid Vector Autoregressive (VAR) – Long Short Term Memory (LSTM) dalam Peramalan Harga Mata Uang Kripto”** sebagai salah satu syarat mendapatkan gelar Sarjana Matematika di Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

Dalam kesempatan ini, penulis mengucapkan terima kasih kepada:

1. Ibu Dr. Dian Kurniasari, S. Si., M.Sc., selaku pembimbing I atas kesediaannya untuk meluangkan waktu, tenaga, dan ilmu serta kritik dan arahan yang membangun untuk penulis menyelesaikan skripsi ini;
2. Bapak Ir. Warsono, M.S., Ph. D., selaku pembimbing II yang telah bersedia memberikan bimbingan, kritik, dan saran dalam proses penulisan skripsi ini;
3. Bapak Prof. Drs. Mustofa Usman, M.A., Ph. D., selaku Pembahas yang juga telah banyak memberikan arahan dan masukan dalam proses penulisan skripsi ini;
4. Ibu Prof. Dr. Asmiati, S. Si., M. Si., selaku Pembimbing akademik yang telah banyak memberikan nasihat dan arahan kepada penulis selama menjalani pendidikan di Jurusan Matematika FMIPA Universitas Lampung;
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung;
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung;
7. Para dosen dan staff Jurusan Matematika FMIPA Universitas Lampung;

8. Papa dan Mama yang selalu berjuang, mendukung, dan mendo'akan setiap proses perjalananku;
9. Kakak-kakak dan para keponakan yang selalu menjadi tempat mengadu dan mendengarkan keluh kesah;
10. Teman seperjuangan Gusti, Rizke, dan Rizki yang menjadi teman perjalanan sejak awal perkuliahan hingga skripsi ini diselesaikan.
11. Teman akhir penelitian Clara, Oktina, Fitri, Vista dan Ikhsan yang telah memantik semangat dan menjadi teman berdiskusi dalam penelitian ini.
12. Mipa T's *family*; Fegy, Yulian, Adel, dan Wais yang menjadi tempat bertanya dan berdiskusi penulis.
13. Keluarga besar HIMATIKA khususnya periode 2020 dan 2021 yang telah memberikan banyak pengalaman dan kenangan.
14. Teman – teman Matematika 2019.
15. Semua pihak yang terlibat dalam penulisan skripsi ini dan tidak bisa penulis sebutkan satu persatu.

Akhir kata, semoga Allah membalas segala kebaikan yang telah kalian berikan. Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan, akan tetapi penulis berharap bahwa skripsi ini dapat berguna dan bermanfaat bagi kita semua.

Bandar Lampung, 11 Juli 2024

Penulis

**Mia Fitriani**

## DAFTAR ISI

	Halaman
<b>DAFTAR ISI</b> .....	i
<b>DAFTAR TABEL</b> .....	iv
<b>DAFTAR GAMBAR</b> .....	v
<b>DAFTAR KODE PROGRAM</b> .....	vi
<b>DAFTAR PERSAMAAN</b> .....	.vii
<b>I. PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	5
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
<b>II. TINJAUAN PUSTAKA</b> .....	6
2.1 Peramalan.....	6
2.2 Analisis Time Series .....	7
2.3 <i>Time Series</i> Univariat .....	8
2.3.1 <i>Autoregressive (AR)</i> .....	8
2.4 <i>Time Series</i> Multivariat.....	9
2.4.1 <i>Vector Autoregressive (VAR)</i> ... ..	9
2.5 Kestasioneran Data .....	11
2.6 Uji Kointegrasi .....	12
2.7 Evaluasi Model.....	12
2.7.1 <i>Akaike Information Criteria (AIC)</i> .....	12
2.7.2 <i>Bayesian Information Criteria (BIC)</i> .....	13

2.7.3 <i>Mean Absolute Percentage Error (MAPE)</i> .....	13
2.8 Data Mining .....	14
2.9 <i>Preprocessing Data</i> .....	15
2.10 Normalisasi Data .....	15
2.11 <i>Machine Learning</i> .....	16
2.12 Fungsi Aktivasi .....	17
2.12.1 <i>Fungsi Sigmoid</i> .....	18
2.12.2 <i>Fungsi Tangen Hiperbolik</i> .....	18
2.13 <i>Reccurent Neural Network (RNN)</i> .....	19
2.14 <i>Long-Short Term Memory (LSTM)</i> .....	20
2.15 <i>Hyperparameter Tuning</i> .....	25
2.16 <i>Hybrid VAR – LSTM</i> .....	25
2.17 <i>Bitcoin</i> .....	27
<b>III. METODOLOGI PENELITIAN .....</b>	<b>28</b>
3.1 Waktu dan Tempat Penelitian .....	28
3.2 Data Penelitian .....	28
3.3. Metode Penelitian.....	29
<b>IV. HASIL DAN PEMBAHASAN.....</b>	<b>32</b>
4.1 <i>Input Data</i> .....	32
4.2 Metode <i>Vector Autoregressive</i> .....	33
4.2.1 Uji Stasioneritas.....	33
4.2.2 <i>Splitting Data</i> .....	35
4.2.3 Menentukan Nilai AIC, BIC, dan Prediksi VAR .....	35
4.3 Peramalan VAR.....	39
4.4 Residual Model VAR .....	43
4.5 Normalisasi Data .....	44
4.6 Model <i>Hybrid VAR-LSTM</i> .....	44
4.6.1 Membangun Model Pertama LSTM .....	45
4.6.2 Membangun Model Kedua LSTM.....	48

4.7 Prediksi dengan Model <i>Hybrid</i> VAR-LSTM.....	51
4.8 Peramalan dengan Model <i>Hybrid</i> VAR-LSTM .....	53
4.9 Perbandingan Hasil Peramalan dengan $T^2$ Hotelling .....	55
<b>V. KESIMPULAN DAN SARAN .....</b>	<b>57</b>
5.1 Kesimpulan .....	56
5.2 Saran .....	56
<b>DAFTAR PUSTAKA .....</b>	<b>58</b>
<b>LAMPIRAN .....</b>	<b>63</b>

## DAFTAR TABEL

Tabel	Halaman
1. Interpretasi nilai MAPE .....	14
2. Data mata uang kripto <i>Bitcoin</i> .....	29
3. Hasil Uji ADF .....	34
4. Hasil Uji ADF setelah <i>Differencing</i> .....	34
5. <i>Splitting</i> Data .....	35
6. Hasil <i>Select Order</i> Skema 80% Data <i>Training</i> & 20% Data <i>Testing</i> .....	36
7. Hasil <i>Select Order</i> Skema 90% Data <i>Training</i> & 10% Data <i>Testing</i> .....	37
8. Hasil Uji $T^2$ <i>Hotelling</i> .....	55



## DAFTAR GAMBAR

Gambar	Halaman
1. Fungsi <i>Sigmoid</i> .....	18
2. Fungsi <i>Tanh</i> .....	19
3. Arsitektur LSTM.....	21
4. Gerbang <i>Forget</i> LSTM .....	21
5. Gerbang <i>Input</i> .....	22
6. Alur Proses Pembaharuan <i>Cell State</i> .....	23
7. Gerbang <i>Output</i> LSTM .....	24
8. Diagram Alir Proses VAR-LSTM .....	31
9. Data Harga Bitcoin .....	32
10. Visualisasi Data Harga Bitcoin.....	33
11. Plot Data Aktual dan Prediksi VAR(14).....	37
12. Plot Data Aktual dan Prediksi VAR(6).....	38
13. Plot Data Peramalan VAR Skema 80:20.....	40
14. Plot Data Peramalan VAR Skema 90:10.....	42
15. Plot Data Residual.....	43
16. Hasil Normalisasi Data.....	44
17. Grafik <i>Loss Function</i> Model LSTM Pertama dengan Skema 80 : 20.....	46
18. Grafik <i>Loss Function</i> Model LSTM Pertama dengan Skema 90:10.....	47
19. Grafik <i>Loss Function</i> Model LSTM Kedua dengan Skema 80:20 .....	49
20. Grafik <i>Loss Function</i> Model LSTM Kedua dengan Skema 90:10 .....	51
21. Visualisasi Hasil Prediksi Model <i>Hybrid</i> VAR-LSTM .....	52
22. Visualisasi Hasil Peramalan Model <i>Hybrid</i> VAR-LSTM 80:20 .....	53
23. Visualisasi Hasil Peramalan Model <i>Hybrid</i> VAR-LSTM 90:10 .....	54

## DAFTAR KODE PROGRAM

Kode Program	Halaman
1. Proses <i>input</i> data .....	32
2. Uji Stasioneritas .....	34
3. Perhitungan Residual VAR .....	43
4. <i>Hyperparameter Tuning</i> Model LSTM Pertama dengan Skema 80:20 .....	45
5. <i>Hyperparameter Tuning</i> Model LSTM Pertama dengan Skema 90:10 .....	46
6. <i>Hyperparameter Tuning</i> Model LSTM Kedua dengan Skema 80:20 .....	48
7. <i>Hyperparameter Tuning</i> Model LSTM Kedua dengan Skema 90:10 .....	49
8. Prediksi Model <i>Hybrid</i> .....	51

## DAFTAR PERSAMAAN

Persamaan	Halaman
(2.1) <i>Autoregressive</i> (AR).....	8
(2.2) <i>Vector Autoregressive</i> (VAR).....	10
(2.3) <i>Akaike Information Criteria</i> (AIC).....	12
(2.4) <i>Mean Absolute Percentage Error</i> (MAPE) .....	13
(2.5) <i>Normalisasi Min-Max</i> .....	16
(2.6) <i>Fungsi Sigmoid</i> .....	18
(2.7) <i>Fungsi Tangen Hiperbolik</i> .....	19
(2.8) <i>Gerbang Forget</i> .....	21
(2.9) <i>Gerbang Input</i> .....	22
(2.10) <i>Kandidat Cell State Baru</i> .....	22
(2.11) <i>Pembaharuan Cell State</i> .....	23
(2.12) <i>Hybrid VAR-LSTM</i> .....	26
(2.13) <i>Residual Model VAR-LSTM</i> .....	26

## I. PENDAHULUAN

### 1.1 Latar Belakang

Pembahasan mengenai mata uang kripto atau yang biasa dikenal dengan sebutan *cryptocurrency* masih sangat hangat hingga saat ini. Kehadiran mata uang kripto merupakan cara yang dapat digunakan dalam mencapai kemudahan transaksi keuangan secara digital, transparan, dan dapat diterima dengan baik oleh kedua pihak yang bertransaksi (Noorsanti dkk., 2018). Berdasarkan peraturan yang berlaku di Indonesia, penggunaan mata uang kripto sebagai alat pembayaran tidak diakui dengan sah dan mata uang yang diterima sebagai alat pembayaran yang sah di mata hukum adalah mata uang Rupiah (Puspasari, 2020). Nilai keuntungan investasi kripto yang tinggi tentunya diikuti pula dengan resiko kerugian yang tinggi karena ketergantungan terhadap teknologi dan antusiasme yang sesaat, serta tidak dapat diprediksinya harga mata uang kripto untuk waktu ke depan (Huda dan Hambali, 2020).

Banyak jenis mata uang kripto yang beredar di tengah kehidupan masyarakat. Bitcoin, Ethereum, Litecoin, Ripple, Cardano, dan Matic merupakan beberapa jenis dari mata uang kripto. Diantara jenis mata uang kripto yang beredar, Bitcoin dan Ethereum merupakan jenis mata uang kripto yang memiliki harga jual dengan tingkat yang cukup tinggi dibandingkan dengan jenis mata uang kripto yang lain. Terdapat empat buah variabel harga dalam penentuan harga mata uang kripto termasuk bitcoin yaitu variabel *Open*, variabel *Low*, variabel *High*, dan variabel *Close*. Variabel *Open* adalah harga pertama kali transaksi dilakukan pada hari

bersangkutan, variabel *Low* dan *High* adalah kisaran harga terendah dan tertinggi dari harga mata uang kripto dalam satu hari yang bersangkutan, dan variabel *Close* adalah variabel yang mencerminkan semua harga atau informasi yang ada pada pelaku pasar saat perdagangan mata uang kripto berakhir di hari yang bersangkutan.

Transaksi Bitcoin pertama kali dilakukan pada tahun 2009. Kemudian, setelah peredarannya selama dua tahun, diperkirakan bahwa sirkulasi transaksi Bitcoin telah terjadi lebih dari US\$ 6,5 juta dengan penggunaannya sekitar 10.000 pengguna (Blau, 2018). Meskipun demikian, sepanjang tahun 2022 Bitcoin diperdagangkan dengan harga yang cukup rendah dan memiliki resiko tinggi. Hal ini merupakan salah satu dampak dari kondisi makro ekonomi sosial dan krisis di perusahaan kripto akibat resesi dan tingkat inflasi yang tinggi. Untuk itu diperlukan suatu metode yang dapat digunakan untuk melakukan peramalan dan prediksi secara akurat mengenai harga mata uang kripto dalam beberapa waktu kedepan.

Salah satu analisis yang dapat digunakan dalam mempersiapkan investasi menggunakan mata uang kripto adalah peramalan harga untuk beberapa periode ke depan. Metode *Vector Autoregressive* (VAR) merupakan salah satu metode yang dapat diterapkan dalam melakukan peramalan. Metode VAR adalah suatu model persamaan dinamis yang pendugaan suatu variabel pada periode tertentu akan dipengaruhi oleh variabel-variabel sebelumnya (Enders, 2004). Metode ini bekerja dengan memperhatikan kestasioneran data dan melihat pengaruh suatu nilai variabel di masa lalu untuk menjelaskan keadaan dimasa sekarang. Kekurangan yang dimiliki metode VAR ini timbul dari jumlah lag yang dipilih dalam suatu persamaan pada model VAR dapat mengakibatkan perlunya data yang relatif banyak. Masih terdapat asumsi linearitas yang harus dipenuhi dan tidak ada pola non linier yang dapat ditangkap oleh model VAR sehingga cukup sulit untuk melakukan peramalan data deret waktu yang memiliki pola non linier menggunakan metode VAR. Metode VAR digunakan untuk mempelajari perilaku dan mengevaluasi data yang ada dan dapat menghasilkan peramalan dengan

akurasi yang baik, namun hasil peramalan dengan metode VAR akan melemah jika digunakan dalam peramalan jangka panjang (Dissanayake dkk, 2021). Metode VAR sendiri

Metode *Long-Short Term Memory* (LSTM) adalah salah satu metode yang bekerja menggunakan sistem jaringan syaraf tiruan dan memiliki prinsip seperti jaringan syaraf manusia.. *Long-Short Term Memory* merupakan suatu metode yang menggunakan berbagai gerbang yang dapat menambah kumpulan informasinya. Model LSTM mampu untuk mengingat kumpulan-kumpulan informasi yang telah tersimpan lama dengan baik (Yu dkk., 2019). Model LSTM dapat memproses, memprediksi, dan mengklasifikasi informasi berdasarkan data deret waktu. Model LSTM memiliki 3 buah gerbang yaitu gerbang *forget*, gerbang *input*, dan gerbang *output*. Selain itu, metode LSTM tidak memiliki asumsi yang harus dipenuhi dalam proses pengolahan data. Model LSTM memiliki kemampuan generalisasi dan *learning* yang baik untuk diterapkan pada analisis himpunan data besar dan kecil, mampu untuk memproses data yang bersifat non linier, dan dapat meningkatkan akurasi peramalan .

Model LSTM menggunakan seluruh informasi yang tersimpan sebagai masukan untuk membangun *deep network* (Hochreiter dan Schmidhuber, 1997). Model LSTM dapat menangkap dan menjelaskan pola non linier yang terkandung dalam data dengan baik. Kelebihan-kelebihan yang dimiliki oleh model LSTM ini diharapkan dapat menutup kekurangan yang muncul dari peramalan dengan metode VAR dan menghasilkan peramalan yang lebih akurat jika dikombinasikan dengan baik.

Hasil dari peramalan tidak dapat dipastikan sesuai dengan keadaan nyata. Namun, terdapat perbedaan antara hasil peramalan dengan data aktual, dimana hal ini biasa disebut dengan *error*. Pada peramalan, tingkat *error* atau akurasi akan diukur menggunakan *Mean Square Error* (MSE), *Mean Absolute Percentage Error* (MAPE), dan *Root Mean Square Error* (RMSE) (Khoiri, 2020).

Penelitian mengenai metode VAR dan LSTM pada peramalan, sudah pernah dilakukan sebelumnya. Penelitian yang dilakukan oleh Saputro dkk. (2011) mengenai peramalan curah hujan menggunakan VAR menunjukkan bahwa nilai RMSE yang cukup baik dan menunjukkan nilai hasil ramalan dan nilai aslinya tidak terlalu jauh. Selanjutnya, penelitian yang dilakukan oleh Owen dkk. (2022) mengenai prediksi pergerakan nilai harga emas menggunakan metode LSTM menunjukkan bahwa nilai *close* antara data aktual dan prediksinya tidak jauh berbeda dan sangat akurat.

Pada penelitian lain yang dilakukan oleh Aji dan Surjandari (2020) untuk meramalkan harga transaksi bahan bakar jet membandingkan metode *Hybrid* VAR-LSTM dan metode *Hybrid* VAR-GRU yang menghasilkan bahwa peralaman dengan metode *Hybrid* VAR-LSTM memiliki tingkat akurasi yang lebih tinggi. Penelitian yang dilakukan oleh Sinha dkk. (2021) untuk meramalkan beban listrik menggunakan metode VAR, MLP, *Hybrid* VAR, LSTM, MV-kWNN, MV-ANN, ARIMAX, dan *Hybrid* VAR-CNN-LSTM. Berdasarkan penelitian yang dilakukan diperoleh bahwa metode *Hybrid* VAR-CNN-LSTM paling efisien dalam melakukan peramalan. Kemudian, penelitian mengenai peramalan yang dilakukan oleh Ouham dan Hadi (2019) untuk memprediksi beban kerja menggunakan metode *Hybrid* VAR-LSTM, *Hybrid* ARIMA-LSTM, dan *Hybrid* RNN-GRU, menunjukkan bahwa hasil peramalan dengan *Hybrid* VAR-LSTM lebih baik dari metode lain

Berdasarkan penjelasan di atas, penelitian ini berfokus pada penggunaan metode *Hybrid* VAR-LSTM untuk meramalkan harga mata uang kripto sehingga dapat digunakan sebagai bahan pertimbangan dan penentuan waktu yang tepat untuk investasi bagi investor mata uang kripto jenis Bitcoin.

## 1.2 Rumusan Masalah

1. Apakah model *hybrid* VAR-LSTM dapat melakukan peramalan data harga mata uang kripto *bitcoin*?
2. Apakah model *hybrid* VAR-LSTM merupakan model dengan performa terbaik untuk peramalan harga mata uang kripto *botcoin*?
3. Apakah skema peramalan terbaik yang dapat diterapkan dalam peramalan harga mata uang kripto *bitcoin* dengan model *hybrid* VAR-LSTM?

## 1.3 Tujuan Penelitian

Tujuan dari dilakukannya penelitian ini adalah:

1. Membangun model terbaik dari metode *Hybrid* VAR-LSTM dalam peramalan harga mata uang kripto
2. Mengkaji performa model peramalan yang dibangun dari metode *Hybrid* VAR-LSTM dalam peramalan harga mata uang kripto
3. Mengetahui hasil peramalan dengan menggunakan metode *Hybrid* VAR-LSTM terhadap harga mata uang kripto

## 1.4 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Memberikan pengetahuan mengenai pembuatan model dan peramalan mata uang kripto
2. Memberikan pengetahuan dan gambaran jangka panjang mengenai peramalan harga mata uang kripto
3. Menjadi referensi bagi penelitian selanjutnya mengenai metode *Hybrid* VAR-LSTM serta peramalan harga mata uang kripto.



## II. TINJAUAN PUSTAKA

### 2.1 Peramalan

Peramalan merupakan suatu metode yang digunakan untuk memperkirakan suatu peristiwa yang akan terjadi di masa depan. Peramalan merupakan salah satu hal yang penting mencakup berbagai bidang seperti bisnis, industri, pemerintahan, ekonomu, sosial, politik, kedokteran, dan keuangan. Masalah peramalan dapat diklasifikasikan menjadi jangka pendek, peramalan jangka menengah. dan peramalan jangka panjang (Montgomery dkk., 2015). Peramalan menggunakan data historis atau data yang ada pada masa lampau yang relevan kemudian digunakan untuk memprediksi data yang akan muncul pada masa mendatang. Keberhasilan dari peramalan ditentukan oleh besarnya selisish antara data hasil ramal dengan data aktualnya (Adnan, 2019).

Peramalan dapat memperkirakan besar dan jumlah kebutuhan dimasa yang akan datang dapat berupa jumlah ataupun kualitas dalam rangka memenuhi kebutuhan. Dengan adanya hasil dari peramalan, maka dapat ditentukan strategi dan keputusan yang tepat dalam melakukan perencanaan lebih lanjut. Sedangkan, menurut Heizer dan Render (2014), peramalan merupakan sebuah seni dan ilmu yang dapat memprediksi peristiwa yang akan terjadi di masa depan menggunakan data yang ada sebelumnya kemudian diproyeksikan untuk memperoleh perkiraan peristiwa yang terjadi di masa depan. Menurut Heizer dan Render (2014), peramalan dapat diklasifikasikan ke dalam panjang masanya, yaitu:

1. Peramalan jangka pendek yang memiliki rentang waktu harian hingga 1 tahun. Namun, umumnya rentang waktu pada peramalan jangka pendek ini adalah 3 bulan.
2. Peramalan jangka menengah yang memiliki rentang waktu umumnya 3 bulan sampai dengan 3 tahun. Peramalan jenis ini berguna dalam perencanaan produksi ataupun rencana penganggaran keuangan.
3. Peramalan jangka panjang yang umumnya memiliki rentang waktu lebih dari 3 tahun. Peramalan jenis ini berguna sebagai perencanaan produksi baru ataupun pengeluaran modal.

## 2.2 Analisis Deret Waktu

Deret waktu merupakan suatu pengamatan mengenai suatu variabel secara berurut dari waktu ke waktu dan dicatat secara dengan interval waktu yang tetap (Wei, 2006). Metode deret waktu merupakan suatu metode peramalan dengan menggunakan pola hubungan variabel waktu dengan variabel yang diramalkan. Terdapat empat macam pola data deret waktu antara lain adalah pola horizontal, musiman, *trend* dan siklis. Analisis deret waktu melibatkan penggunaan data deret waktu atau data deret waktu untuk membuat model peramalannya.

Data deret waktu merupakan data berurut yang diperoleh dari pengukuran pada interval waktu yang berurutan. Deret waktu adalah seluruh nilai yang ada pada interval yang sama dan berurutan dengan waktu sebagai indeksnya. Data deret waktu adalah kumpulan data pengamatan yang didapatkan dari pencatatan dari waktu ke waktu dalam jangka waktu tertentu. Data deret waktu dianalisis menggunakan model analisis deret waktu sehingga dapat terarah dalam memahami pola yang ada pada data (Brillinger, 2001).

Secara garis besar, terdapat dua teknik dalam analisis deret waktu yaitu analisis dengan satu variabel (*univariate*) dan analisis dengan melibatkan lebih dari satu variabel (*multivariate*).

### 2.3 Deret waktu Univariat

Model deret waktu univariat adalah suatu model data deret waktu yang digunakan untuk menganalisa data yang memiliki satu variabel. Salah satu model dari deret waktu univariat adalah model *Autoregressive* (AR).

#### 2.3.1 *Autoregressive* (AR)

*Autoregressive* adalah suatu model deret waktu univariat yang digunakan untuk meramalkan informasi pada periode ke depan dengan menghubungkan informasi masa lalu pada selang waktu yang beragam. Data yang digunakan dalam model ini adalah data deret waktu stasioner (Makridakis dkk., 1999). Persamaan (2.1) merupakan persamaan yang digunakan dalam model ini, yaitu sebagai berikut :

$$Y_t = \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t \quad (2.1)$$

dengan:

$y_t$  = variabel dependen

$y_{t-1}$  = nilai masa lalu yang memiliki hubungan

$\beta_p$  = koefisien dari model AR

$\varepsilon_t$  = nilai *error* pada waktu ke - t (residual)

## 2.4 Deret waktu Multivariat

Model deret waktu multivariat adalah model data deret waktu untuk menganalisis data yang memiliki lebih dari satu variabel dan membentuk suatu sistem. Model sistem ini dapat terbagi menjadi model dengan hubungan bolak-balik dan model dengan hubungan yang tidak bolak-balik, tetapi terdapat satu variabel yang dipengaruhi variabel lain. Salah satu model dari deret waktu multivariat adalah model *vector autoregressive* (VAR).

### 2.4.1 *Vector Autoregressive* (VAR)

*Vector Autoregressive* merupakan suatu model generalisasi dari *Autoregressive* yang memiliki variabel lebih dari satu. Metode VAR adalah suatu model persamaan dinamis yang pendugaan suatu variabel pada periode tertentu akan dipengaruhi oleh variabel-variabel sebelumnya (Enders, 2004). Metode VAR merupakan salah satu metode yang dapat digunakan untuk memproyeksikan suatu keadaan di suatu waktu ke waktu tertentu di masa depan. VAR adalah suatu metode deret waktu *multivariate* yang dapat digunakan untuk meramalkan lebih dari satu variabel. Pada model ini, setiap variabel dimodelkan sebagai suatu kombinasi linier dari pengamatan yang ada di masa lalu terhadap dirinya sendiri dan variabel lainnya (Dissanayake dkk., 2021).

Model VAR merupakan model peramalan yang dapat digunakan untuk menganalisa hubungan variabel-variabel runtun waktu untuk melakukan analisis dampak dinamis dari gangguan yang ada di variabel tersebut. Model VAR merupakan salah satu model peramalan yang sederhana karena tidak perlu memperhatikan adanya variabel terikat dan variabel tidak terikat. Masing-masing variabel diterangkan oleh nilai-nilainya di masa lampau. Pendekatan yang dilakukan oleh model VAR merupakan kombinasi dari regresi multivariate dan analisis deret

waktu. Model VAR seringkali digunakan dalam peramalan untuk jangka panjang maupun menengah.

Menurut Widarjono (2007), model VAR tidak bersifat teoritis atau tidak memperhatikan teori-teori yang ada sebelumnya sehingga dapat dikatakan bahwa model VAR bersifat *unstructural*. Penggunaan banyak variabel pada peramalan dengan model VAR akan menimbulkan lebih banyak resiko karena semakin banyak variabel yang harus diestimasi maka derajat bebasnyapun semakin banyak berkurang. Beberapa keunggulan dari metode VAR antara lain, yaitu:

1. Tidak membedakan antara variabel dependen dan independen,
2. Metode estimasinya sederhana yaitu dengan menggunakan metode kuadrat terkecil.

Menurut Wei (2018), model VAR dengan orde  $p$  yang memiliki  $n$  buah variabel pada waktu ke- $t$  ditulis pada persamaan (2.2) sebagai berikut:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t \quad (2.2)$$

dengan:

$Y_t$  = vektor variabel terikat

$\beta_0$  = vektor intersep

$\beta_i$  = matriks parameter berukuran  $m \times m$  untuk setiap  $i = 1, 2, \dots, p$

$\varepsilon_t$  = nilai *error* pada waktu ke -  $t$  (residual)

Diperlukan pemeriksaan lag optimal sebelum melakukan peramalan dan analisis dengan model VAR yang dapat dilakukan dengan menggunakan *Akaike Information Criteria* (AIC). Kelemahan dari metode VAR adalah tidak mampu dalam menangkap pola nonlinier

## 2.5 Kestasioneran Data

Kestasioneran data adalah hal yang dapat meminimalisir kesalahan model pada analisis deret waktu (Rahayu dkk., 2021). Data yang stasioner menunjukkan bahwa tidak ada perubahan yang signifikan di dalam data. Data bergerak stabil dan konvergen menyebar rata di sekitar rata-rata dan simpangan baku. Kestasioneran pada data multivariat dapat dilihat dengan menggunakan plot fungsi matriks autokorelasi dan plot fungsi matriks autokorelasi parsial dari data awal. Data dapat dikatakan belum stasioner jika nilai matriks fungsi autokorelasi turun melambat menuju nol secara signifikan. Data dapat dikatakan stasioner dalam rata-rata jika rata-ratanya cenderung konstan atau stabil dari waktu ke waktu. Data yang dikatakan stasioner dalam varians adalah jika data mengalami fluktuasi yang konstan.

Menurut Febrianti dkk. (2021), stasioneritas data dapat dideteksi dengan menggunakan uji akar unit menggunakan uji *Augmented Dickey Fuller* (ADF). Uji ini bertujuan untuk memeriksa apakah koefisien tertentu dalam model mempunyai nilai 1. Apabila data stasioner pada level  $[I(0)]$  maka dilakukan uji korelasi. Apabila tingkat korelasinya rendah, maka data dianalisis menggunakan metode VAR in level. Namun, apabila data tidak stasioner, maka harus dilakukan transformasi stasioneritas melalui proses diferensi. Jika data stasioner pada *first difference*  $[d=1]$  maka harus dilanjutkan dengan melakukan uji kointegrasi.

Berdasarkan uji akar unit dengan uji ADF, diperoleh *p-value* yang digunakan untuk menentukan kriteria uji hipotesis kestasioneran data. Jika *p-value* bernilai 1 maka variabel Y tidak stasioner. Namun, jika *p-value* bernilai tidak sama dengan 1 maka variabel Y stasioner. Dengan kriteria ujinya adalah Tolak  $H_0$  apabila *p-value* lebih dari nilai  $\alpha$  yang berarti data tersebut stasioner.

## 2.6 Uji Kointegrasi

Uji kointegrasi atau *Cointegration Test* merupakan uji yang berfungsi untuk melihat hubungan jangka panjang antar variabel yang diamati. Uji-uji yang dapat dilakukan adalah uji Johansen Cointegration Test, Eagle Granger Test, dan Uji Durbin-Watson. Apabila data tidak mengandung kointegrasi maka data dapat dianalisis menggunakan VAR dalam *difference*. Eagle dan Granger (1987) mengungkapkan kointegrasi sebagai kombinasi linear dari dua atau lebih variabel yang tidak stasioner menjadi stasioner.

## 2.7 Evaluasi Model

### 2.7.1 Akaike Information Criteria (AIC)

*Akaike Information Criteria* (AIC) adalah salah satu kriteria pemilihan model terbaik dimana parameter menjadi pertimbangan pengambilan keputusannya (Rizki dan Teguh, 2021). Nilai AIC yang paling minimum memberikan informasi penentuan model dengan kinerja terbaik. AIC dapat diperoleh dengan persamaan (2.3) sebagai berikut:

$$AIC(p) = \ln|\hat{\Sigma}_p| + \frac{2k^2p}{n} \quad (2.3)$$

dengan:

$|\hat{\Sigma}_p|$  = matriks dugaan varian kovarian residual p

k = banyaknya parameter pada model

p = orde lag AR

n = banyaknya pengamatan

ln = log natural

### 2.7.2 *Bayesian Information Criteria (BIC)*

*Bayesian Information Criteria* merupakan suatu kriteria pemilihan model yang paling cocok dengan data yang tersedia dengan mempertimbangkan kompleksitas model tersebut (Kedkk., 2021). Model dengan BIC terkecil menyeimbangkan antara data yang baik dan kompleksitas yang rendah sehingga dapat mencegah model yang terlalu kompleks.

### 2.7.3 *Mean Absolute Percentage Error (MAPE)*

*Mean Absolute Percentage Error* dapat diperoleh dengan menghitung kesalahan *absolute* pada setiap periode kemudian dibagi dengan data aktual yang ada pada periode bersangkutan kemudian menghitung rata-rata kesalahan persentase absolut tersebut. Model prediksi dapat dikatakan akurat apabila memperoleh nilai MAPE yang rendah. Nilai MAPE memberikan informasi mengenai besarnya kesalahan yang terjadi pada peramalan yang dibandingkan. Nilai MAPE adalah suatu persentase kesalahan rata-rata secara mutlak mengenai akurasi suatu peramalan (Khoiri, 2020).

Jika dituliskan kedalam rumus matematis, perhitungan MAPE ditulis dengan persamaan (2.4) sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_t - F_t}{x_t} \right| \quad (2.4)$$

dengan:

$n$  = ukuran sampel (banyaknya data)

$x_t$  = nilai data aktual

$F_t$  = nilai peramalan.



Jika dilihat berdasarkan intervalnya, nilai MAPE dapat diinterpretasikan ke dalam empat kelompok yaitu sangat akurat, baik, layak, dan tidak akurat. Kriteria nilai MAPE dapat dilihat pada Tabel 1 sebagai berikut (Zhang dkk., 2015) :

Tabel 1. Interpretasi nilai MAPE

<b>Nilai MAPE</b>	<b>Interpretasi</b>
< 10	Hasil peramalan akurat
10 – 20	Hasil peramalan baik
21 – 50	Hasil peramalan layak (cukup baik)
>50	Hasil peramalan tidak akurat

## 2.8 Data Mining

Data mining adalah suatu rangkaian proses untuk memperoleh pengetahuan baru dari suatu kumpulan datayang sangat besar dengan mencari pola aturan tertentu yang kemudian disimpan dalam suatu basis data. Data mining berkaitan dengan sistem basis data, *data warehouse*, *mechine learning*, *information retrieval*, dan komputasi. Data mining bekerja dengan dilengkapi oleh jaringan syaraf tiruan, pengenalan pola, data spasial, analisis data gambar ataupun *signal* (Han dan Kember, 2006). Data mining dapat pula diartikan sebagai suatu proses yang dilakukan untuk memperoleh suatu informasi yang berguna dari suatu data besar yang perlu diekstrak agar menjadi informasi baru dan dapat digunakan sebagai pertimbangan mengambil keputusan (Suntoro, 2019). Data mining dapat didefinisikan sebagai suatu proses menganalisa data dari basis yang berbeda dan menyimpulkannya menjadi suatu informasi penting yang dapat meningkatkan keuntungan, memperkecil pengeluaran, atau bahkan keduanya .Berdasarkan beberapa definisi diatas, dapat diambil kesimpulan bahwa data mining merupakan suatu cara yang digunakan untuk mencari informasi berharga dari kumpulan data yang sangat besar dengan menemukan pola tertentu yang belum diketahui. Metode dalam data mining antara lain *clustering*, *association*, dan jaringan syaraf tiruan (*neural network*).

## 2.9 Preprocessing Data

*Preprocessing data* adalah suatu tahap awal untuk mempersiapkan data yang akan diolah lebih lanjut dalam memperoleh suatu informasi. Tahap ini meliputi *data cleaning*, *data integration*, transformasi data, dan perubahan struktur data menjadi bentuk *supervised learning* (Haryatmi dan Sheila, 2021). *Data cleaning* dilakukan dengan tujuan untuk memastikan bahwa tidak terdapat data hilang dan memastikan bahwa data yang ada diperlukan dalam proses analisis. *Data integration* bertujuan untuk memastikan data yang ada memiliki format yang sama, hal ini biasa dilakukan untuk menyamakan format data yang sumbernya berbeda. Bentuk *supervised learning* akan mengenali pola antara data input dan outputnya.

Pada data deret waktu nilai input yang digunakan adalah data masa lalu dan *output* yang diperoleh adalah data pada masa mendatang. Dengan demikian, untuk melakukan peramalan data di masa mendatang dengan data mining, maka perlu dilakukan perubahan dari data deret waktu menjadi bentuk *supervised learning*.

## 2.10 Normalisasi Data

Normalisasi data adalah suatu teknik yang dilakukan untuk mengubah nilai numerik dalam suatu kumpulan data ke skala umum menimbulkan perbedaan makna dalam rentang nilainya dengan memperkecil ukuran data tanpa mengubah data aktual. Tujuan dari *scaling data* adalah untuk menormalkan data agar dapat mempercepat proses pembelajaran pada *machine learning*. *Min-max scaling* adalah teknik yang dapat dilakukan untuk menormalisasi data dengan cara mengubah data aktual menjadi nilai dengan interval  $[0,1]$  agar nilai perbandingan data yang dihasilkan sebelum dan sesudah proses seimbang (Hanif dkk, 2017).

Persamaan (2.5) merupakan persamaan yang digunakan dalam normalisasi *min-max scaling* sebagai berikut (Nasution dkk., 2019):

$$X' = \frac{x - [\text{minValue}]}{\text{maxValue} - \text{minValue}} \quad (2.5)$$

dengan:

$X'$  = data hasil normalisasi

$x$  = data aktual

$\text{minValue}$  = nilai minimum dari data  $x$

$\text{maxValue}$  = nilai maksimum dari data  $x$

## 2.11 Machine Learning

Menurut Mitchell (1997), *machine learning* adalah suatu pembelajaran mengenai masalah yang ada berdasarkan pengalaman data dan meningkatkan kinerja program secara otomatis dari data yang ada sebelumnya. Cara kerja dari *machine learning* yaitu dengan mengumpulkan, memeriksa, dan membandingkan data dari yang berukuran kecil sampai yang berukuran besar untuk menemukan pola tertentu. Pengalaman mengacu pada informasi masa lalu yang termuat dalam data elektronik yang tersedia dalam bentuk kumpulan data untuk dianalisis. Pada *machine learning*, terdapat ciri khas yaitu adanya proses *training dan testing* (Mohri dkk., 2019). *Machine learning* merupakan tipe dari kecerdasan buatan yang memiliki kemampuan untuk belajar dari data tanpa instruksi eksplisit yang terprogram sehingga mampu belajar sendiri tanpa harus dilakukan pemrograman berulang kali oleh manusia (Budiharto, 2016).

*Machine learning* mengembangkan system yang dapat melakukan pembelajaran secara mandiri untuk menghasilkan suatu keluaran tanpa harus melakukan program berulang kali oleh manusia. Metode ini menciptakan kemampuan untuk menentukan aturan dalam pengambilan keputusan ketika melakukan analisis dari kumpulan data berukuran besar.

*Machine learning* terbagi menjadi 3 jenis, yaitu:

1. *Supervised Learning* yaitu algoritma yang menggunakan *training dataset* untuk melakukan prediksi dan klasifikasi (Roihan dkk., 2020). Proses pembelajaran akan berhenti ketika algoritma telah memperoleh *output* yang diinginkan. Algoritma *supervised learning* digunakan untuk memodelkan hubungan ketergantungan antara target keluaran yang diperoleh dan nilai *input* sehingga akan diperoleh hasil prediksi data baru dari hubungan pada data sebelumnya.
2. *Unsupervised Learning* merupakan algoritma yang digunakan untuk membaca pola dan model. Algoritma ini tidak memiliki data *training* maupun *testing*. Metode *unsupervised learning* yang umum dipakai adalah analisis *cluster* untuk mencari pola tersembunyi pada data (Alloghani dkk., 2019).
3. *Reinforcement Learning* yaitu algoritma yang bertujuan untuk memaksimalkan keluaran dan meminimalkan resiko yang akan timbul dalam waktu yang telah ditentukan. Algoritma ini mampu menemukan perlakuan yang menghasilkan keluaran terbaik dari hasil *trial and error*.

## 2.12 Fungsi Aktivasi

Fungsi aktivasi adalah penentu aktif atau tidaknya suatu neuron. Fungsi aktivasi akan merespon suatu rangsangan yang diterima dengan efek tertentu. Hal ini menyebabkan fungsi aktivasi menjadi penyaring informasi yang masuk dan menghasilkan suatu keluaran dengan rentang tertentu. Rentang ini mengubah data non linier menjadi linier (Pasaribu dkk., 2020). Terdapat dua fungsi aktivasi yang biasa digunakan, yaitu:

### 2.12.1 Fungsi Sigmoid

Fungsi *sigmoid* adalah fungsi yang digunakan dalam proses pembaharuan informasi. Jika semakin kecil nilai *input* pada fungsi *sigmoid* maka nilai *output*

yang diperoleh akan mendekati nol. Fungsi *sigmoid* menghasilkan *output* dengan kisaran antara 0 sampai dengan 1 (Chen dkk., 2020). Persamaan fungsi *sigmoid* ditulis pada persamaan (2.6) sebagai berikut:

$$S(x) = \frac{1}{1 + e^{-x}} \quad (2.6)$$


dengan:

$x$  = data

$e$  = bilangan *euler*

$S(x)$  = fungsi *sigmoid*

Fungsi *sigmoid* diilustrasikan pada Gambar 1 sebagai berikut :



Gambar 1. Fungsi *Sigmoid*

### 2.12.2 Fungsi Tangen Hiperbolik

Fungsi tangen hiperbolik adalah fungsi yang digunakan sebagai penyimpanan nilai baru dari proses fungsi *sigmoid*. Rentang nilai fungsi tangen hiperbolik adalah antara -1 sampai 1. Fungsi tangen hiperbolik dapat memberikan keluaran terpusat pada nol sehingga membantu proses distribusi balik. Persamaan fungsi tangen hiperbolik dituliskan pada persamaan (2.7) sebagai berikut:


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

dengan:

$x$  = data

$e$  = bilangan euler

Fungsi  $\tanh x$  diilustrasikan pada Gambar 2 sebagai berikut :



Gambar 2. Fungsi  $\tanh x$

### 2.13 Recurrent Neural Network (RNN)

*Recurrent Neural Network* adalah uatu jenis dari *Neural Network* yang dapat memproses data teks, audio, dan video. Model RNN merupakan suatu jaringan berulang sel sigmoid dan sel tanh. Model RNN menggunakan informasi yang ada untuk memprediksi kejadian dan informasi yang akan muncul di masa depan. Menurut Yu dkk, (2019), model RNN memiliki kapasitas untuk melakukan pembaharuan keadaan aktual berdasarkan informasi masa lalu dan saat ini.

Model RNN terbangun dari tiga buah layer yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Model RNN tidak memiliki kemampuan yang baik untuk menyimpan informasi jangka panjang. Hal ini menyebabkan muncul usulan untuk menemukan model yang mampu mengatasi kelemahan model RNN


dalam mengatasi masalah gradien hilang yaitu model *Long-Short Term Memory* (LSTM).

#### **2.14 Long-Short Term Memory (LSTM)**

*Long-Short Term Memory* adalah tipe spesifik dari RNN yang menangkap informasi jangka panjang secara mandiri untuk meramalkan kejadian di masa depan. Model LSTM memperkenalkan memori jangka panjang ke dalam jaringan syaraf berulang (Afzali dkk., 2021). Model LSTM dapat mengatasi kekurangan metode peramalan klasik. Model LSTM menggunakan pengamatan pada tahap sebelumnya untuk menggambarkan pola yang akan ada di masa depan dengan karakteristik tambahan untuk mengingat urutan informasi (Dissanayake dkk., 2021).

Model LSTM memiliki kemampuan generalisasi dan *learning* yang baik untuk diterapkan pada analisis himpunan data besar dan kecil, mampu untuk memproses data yang bersifat non linier, dan dapat meningkatkan akurasi peramalan. Model LSTM menggunakan seluruh informasi yang tersimpan sebagai masukan untuk membangun *deep network* (Hochreiter dan Schmidhuber, 1997). Model LSTM memiliki tiga buah lapisan yaitu lapisan *input*, lapisan tersembunyi dan lapisan *output*. Pada model LSTM terdapat dua buah fungsi aktivasi yaitu fungsi aktivasi tanh dan fungsi aktivasi *sigmoid*.


Model LSTM memiliki struktur gerbang yang digunakan untuk mempertahankan informasi jangka panjang dan jangka pendek dalam sel memori. Terdapat tiga buah gerbang dalam LSTM yaitu gerbang *input*, gerbang *output*, dan gerbang *forget*. Arsitektur LSTM dapat direpresentasikan dalam Gambar 3 sebagai berikut:



Gambar 3. Arsitektur LSTM

Gambar 3 menunjukkan arsitektur dari model LSTM yang mempunyai *cell state* pada waktu  $t$  dan direpresentasikan sebagai  $C_t$ . *Cell state* memperbaharui informasi yang masuk menggunakan tiga gerbang yang ada yaitu gerbang *input*, gerbang *forget*, dan gerbang *output*. Gerbang *input*, gerbang *forget*, dan gerbang *output* mempengaruhi keadaan dari node pada saat menghitung status simpul lapisan tersembunyi (Sari dkk., 2020).

Gerbang *forget* berguna untuk menyaring informasi yang akan dibuang dari  $C_{t-1}$ . Hal ini dilakukan oleh lapisan *sigmoid* dengan membaca nilai  $s_{t-1}$  dan  $x_t$  kemudian menampilkan angka 1 sebagai “simpan” atau angka 0 sebagai “hilangkan”. Arsitektur gerbang *forget* diilustrasikan dengan *background* berwarna hijau pada Gambar 4 sebagai berikut:



Gambar 4. Gerbang Forget LSTM

Persamaan (2.8) merupakan persamaan yang digunakan dalam gerbang *forget* sebagai berikut:

$$f_t = \sigma(W_f[s_{t-1}, x_t] + b_f) \quad (2.8)$$



dengan:

$f_t$  = gerbang *forget*

$\sigma$  = fungsi *sigmoid*

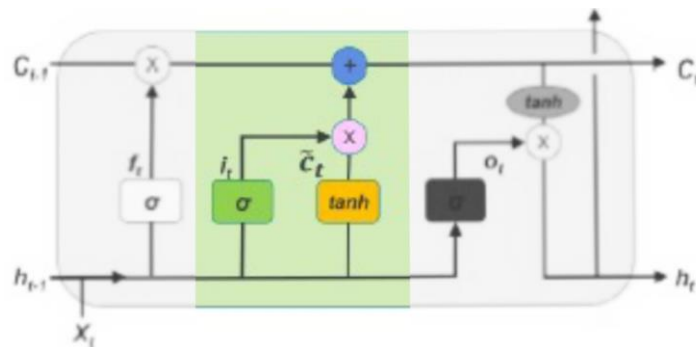
$W_f$  = bobot pada gerbang *forget*

$s_{t-1}$  = hasil *output* pada *time step* 1

$x_t$  = *input* pada *time step* t

$b_f$  = bias pada gerbang *forget*

Gerbang *input* digunakan untuk memutuskan banyaknya input dan informasi baru yang akan disimpan dalam  $C_t$ . Gerbang *input* memiliki dua fungsi yaitu fungsi sigmoid yang memutuskan nilai yang akan diperbaharui dan fungsi tanh yang menghasilkan suatu vektor baru yang akan ditambahkan ke  $\tilde{C}_t$ . Kemudian, dibuat pembaharuan informasi pada *cell state* dengan cara menggabungkan kedua bagian tersebut. Selanjutnya, arsitektur gerbang *input* diilustrasikan dengan *background* berwarna hijau pada Gambar 5 sebagai berikut:



Gambar 5. Gerbang *Input* LSTM

Persamaan (2.9) dan (2.10) merupakan persamaan yang digunakan dalam gerbang *input* sebagai berikut:

$$i_t = \sigma(W_i[s_{t-1}, x_t] + b_i) \quad (2.9)$$

$$\tilde{C}_t = \tanh(W_c[s_{t-1}, x_t] + b_c) \quad (2.10)$$

dengan:

$i_t$  = gerbang *input*

$\sigma$  = fungsi *sigmoid*

$W_i$  = bobot pada gerbang *input*

$s_{t-1}$  = hasil *output* pada *time step* 1

$x_t$  = *input* pada *time step* t

$b_i$  = bias pada gerbang *input*

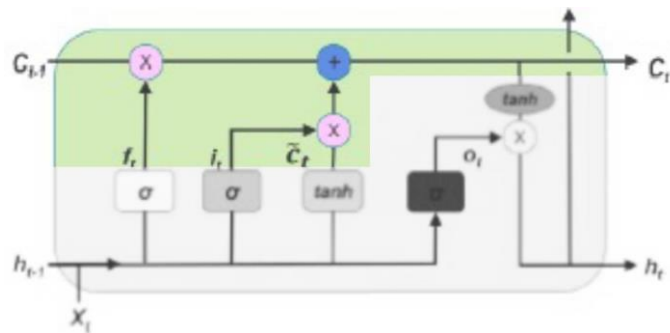
$\tilde{C}_t$  = kandidat nilai *cell state* baru yang akan ditambahkan ke  $C_{t-1}$

$\tanh x$  = fungsi tangen hiperbolik

$W_C$  = bobot pada operasi *cell state* baru

$b_C$  = bias pada operasi *cell state* baru

Perkalian antara  $f_t$  dengan *cell state* lama akan memperoleh keputusan mengenai informasi yang akan dilupakan. Kemudian operasi perkalian antara  $\tilde{C}_t$  dengan  $i_t$  akan memutuskan informasi yang disertakan ke *cell state* baru. Kemudian, tambahkan hasil dari dua operasi perkalian yang telah dilakukan. Ilustrasi pembaharuan *cell state* ditampilkan dengan *background* berwarna hijau pada Gambar 6 sebagai berikut:



Gambar 6. Alur Proses Pembaharuan *Cell State*

Persamaan (2.11) merupakan persamaan yang digunakan pada operasi pembaharuan *cell state* sebagai berikut:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.11)$$

dengan:

$C_t$  = *cell state* pada *time step* t


$f_t$  = gerbang *forget*

$C_{t-1}$  = *cell state* pada *time step* t-1

$\tilde{C}_t$  = nilai *cell state* baru pada hasil perhitungan *input gate*

$i_t$  = gerbang *input*

Gerbang *output* berdasar pada nilai dalam *cell state* tetapi melalui filter. Langkah pertama pada gerbang *output* adalah menjalankan fungsi *sigmoid* untuk memutuskan hasil yang diperoleh dari *cell state*. Kemudian menjalankan *cell state* melalui fungsi *tanh* untuk mengubah nilainya menjadi diantara -1 sampai 1 dan mengalikan dengan hasil dari fungsi *sigmoid* sehingga hanya menghasilkan keputusan. Gerbang *output* diilustrasikan dengan *background* berwarna hijau pada Gambar 7 sebagai berikut:



Gambar 7. *Output Gate* LSTM

Model LSTM merupakan suatu modifikasi dari RNN dengan menambahkan *cell state* atau *memory cell* sehingga dapat menyimpan informasi dalam jangka panjang. Metode ini dapat digunakan untuk mengatasi adanya *vanishing gradient* saat memproses data yang panjang (Manaswi, 2018). Lapisan *sigmoid* akan memproses informasi yang masuk dari *cell state* untuk terus diproses atau dihentikan dengan kemampuannya menambah dan menghapus informasi. Gerbang *forget* akan memilih informasi yang akan dihapus dari *cell*. Kemudian gerbang *input* memutuskan nilai untuk diproses pada *state memory* dan gerbang *output* akan memutuskan apa yang dihasilkan sebagai *output*.

### 2.15 *Hyperparameter Tuning*

*Hyperparameter tuning* adalah nilai estimasi dari parameter yang digunakan untuk mempengaruhi algoritma pembelajaran. Faktor – faktor yang berperan dalam *hyperparameter tuning* adalah *batch size*, bobot, dan *epoch*. *Hyperparameter tuning* adalah proses dari pengidentifikasian *tuple hyperparameter* yang menghasilkan model terbaik dan meminimalkan fungsi kerugian. Nilai – nilai yang dihasilkan dari beberapa faktor dalam *hyperparameter tuning* disebut dengan *hyperparameter*. *Hyperparameter* adalah variabel konfigurasi yang harus dipertimbangkan saat membangun model karena berkaitan dengan kinerja dan nilai akurasi yang dihasilkan model. *Hyperparameter* digunakan untuk mengoptimisasi *output* salah satunya nilai akurasi dari pemodelan (Isa dan Junedi, 2022).

*Hyperparameter* tidak dapat dipelajari secara otomatis dari data *training*. *Machine learning* harus menentukan *hyperparameter* sebelum pembelajaran dengan melakukan *trial and error* agar mendapatkan hasil ramalan yang paling baik.

### 2.16 *Hybrid VAR – LSTM*

Metode *Hybrid* adalah suatu pengembangan metode dalam peramalan data dengan mengkombinasikan dua buah metode, salah satunya penggabungan metode VAR dan LSTM. Menurut Zhang (2003), pengembangan metode *hybrid* dilakukan dengan beberapa alasan yang mendasari dan dapat memberikan solusi dari beberapa permasalahan sebagai berikut:

1. Meningkatkan efektifitas dalam menangkap dan menganalisa pola data linier maupun non linier. Penentuan pola linier atau non linier pada data deret waktu cukup sulit dilakukan sehingga diperlukan penggunaan lebih dari satu metode. Selain itu, jarang terjadi permasalahan deret waktu yang benar – benar linier

ataupun non linier sehingga tidak cukup untuk melakukan analisa dan peramalan hanya menggunakan satu buah metode saja. Model *hybrid* dapat memperkecil kesalahan tersebut.

2. Mengatasi kekurangan metode tunggal yang tidak bisa menangkap pola data yang beragam dalam data dalam satu kasus dengan baik.

Model *hybrid* VAR dan LSTM merupakan salah satu model yang dapat digunakan untuk mengatasi masalah linier dan nonlinier. Teratasinya masalah linier dan non linier ini, akurasi peramalan dapat ditingkatkan. Menurut Zhang (2003), umumnya kombinasi model deret waktu yang memiliki struktur autokorelasi linier dan non linier dengan persamaan (2.12) sebagai berikut:

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

di mana:

$y_t$  : nilai aktual ke t

$L_t$  : komponen linier ke t

$N_t$  : komponen nonlinier ke t

$t$  : indeks waktu

Komponen linier dan nonlinier yang diperlukan dalam model *hybrid* ini diperoleh dengan melakukan ramalan data menggunakan model VAR dan digunakan sebagai komponen linier. Kemudian, melakukan ramalan dari residual model linier sebagai komponen nonlinier. Misal,  $e_t$  adalah residual dari model linier ketika periode waktu t dituliskan dengan persamaan (2.13) sebagai berikut:

$$e_t = Y_t - \hat{Y}_t \quad (2.13)$$

di mana :

$Y_t$  : Nilai aktual ke t

$\hat{Y}_t$  : Komponen linier ke t

$t$  : indeks waktu

$e_t$  : nilai residual ke t

Terdapat dua langkah dalam melakukan metode *hybrid*. Pertama, model VAR digunakan sebagai bahan untuk melakukan prediksi pada bagian linier. Kedua, model LSTM digunakan untuk memodelkan bagian residual dari model VAR yang telah diperoleh dan memproses bagian nonlinier yang tidak tertangkap oleh model VAR. Langkah – langkah utama dalam melakukan pemodelan dengan metode ini adalah sebagai berikut:

1. Melakukan pemodelan setiap komponen linier menggunakan VAR.
2. Memodelkan komponen linier dari VAR dan komponen nonlinier menggunakan LSTM.
3. Melakukan penggabungan antara kedua model yang telah diperoleh.

### **2.17 Bitcoin**

*Bitcoin* muncul setelah terbitnya sebuah artikel yang ditulis oleh Nakamoto pada tahun 2008 dan dikirim ke dalam forum kriptografi. Kemudian, pada tahun tersebut pula terjadi pembelian suatu domain yang bernama *bitcoin.org* dan muncul bitcoin pada tahun 2009. *Bitcoin* diciptakan dengan tujuan memenuhi keinginan memudahkan transaksi secara online tanpa adanya pihak ketiga.

*Bitcoin* merupakan mata uang kripto dengan valuasi pasar terbesar di dunia. Perdagangan *bitcoin* termasuk ke dalam aktivitas beresiko tinggi jika dibandingkan dengan transaksi mata uang konvensional karena harganya yang sangat fluktuatif (Juanda dkk, 2018).

Setiap transaksi *bitcoin* tercatat dalam suatu daftar publik yang disebut *blockchain*. *Blockchain* merupakan suatu konsep yang menggabungkan setiap pihak dalam suatu jaringan yang terdistribusi dan memiliki akses ke dalam pencatatan tersebut.

### III. METODOLOGI PENELITIAN

#### 3.1 Waktu dan Tempat Penelitian

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

#### 3.2 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data harian yang termuat dalam situs Kaggle dengan [link https://www.kaggle.com/datasets/varpit94/bitcoin-data-updated-till-26jun2021](https://www.kaggle.com/datasets/varpit94/bitcoin-data-updated-till-26jun2021). Data yang tersedia memiliki 5 buah variabel yaitu *Open*, *High*, *Low*, *Close*, dan *Volume*. Variabel yang digunakan dalam penelitian ini adalah variabel yang memuat harga *bitcoin* dalam satu hari antara lain :

1.  $Y_1$  : Variabel *Open* adalah variabel harga pembukaan dari bitcoin.
2.  $Y_2$  : Variabel *high* merupakan harga tertinggi dari penjualan bitcoin.
3.  $Y_3$  : Variabel *low* adalah harga terendah penjualan.
4.  $Y_4$  : Variabel *close* adalah harga penutupan bitcoin.

Data yang digunakan pada penelitian ini adalah data historis dari harga pembukaan, tertinggi, terendah, dan penutup mata uang kripto Bitcoin yang diambil selama 5 tahun dan merupakan data harian. Periode waktu yang

digunakan adalah sejak bulan Januari 2017 sampai dengan Februari 2022. Empat variabel yang digunakan berkaitan dengan metode VAR yang merupakan metode multivariate sehingga memerlukan lebih dari satu variabel. Data dapat diunduh secara langsung dengan bentuk *CSV*.

Tabel 2. Data mata uang kripto *Bitcoin*

<i>Date</i>	$Y_1$	$Y_1$	$Y_1$	$Y_1$
01-01-2017	963.658	1003.08	958.699	998.325
02-01-2017	998.617	1031.39	996.702	1021.75
03-01-2017	1021.6	1044.08	1021.6	1043.84
⋮	⋮	⋮	⋮	⋮
19-02-2022	40022.13	40246.03	40010.87	40126.43

### 3.3 Metode Penelitian

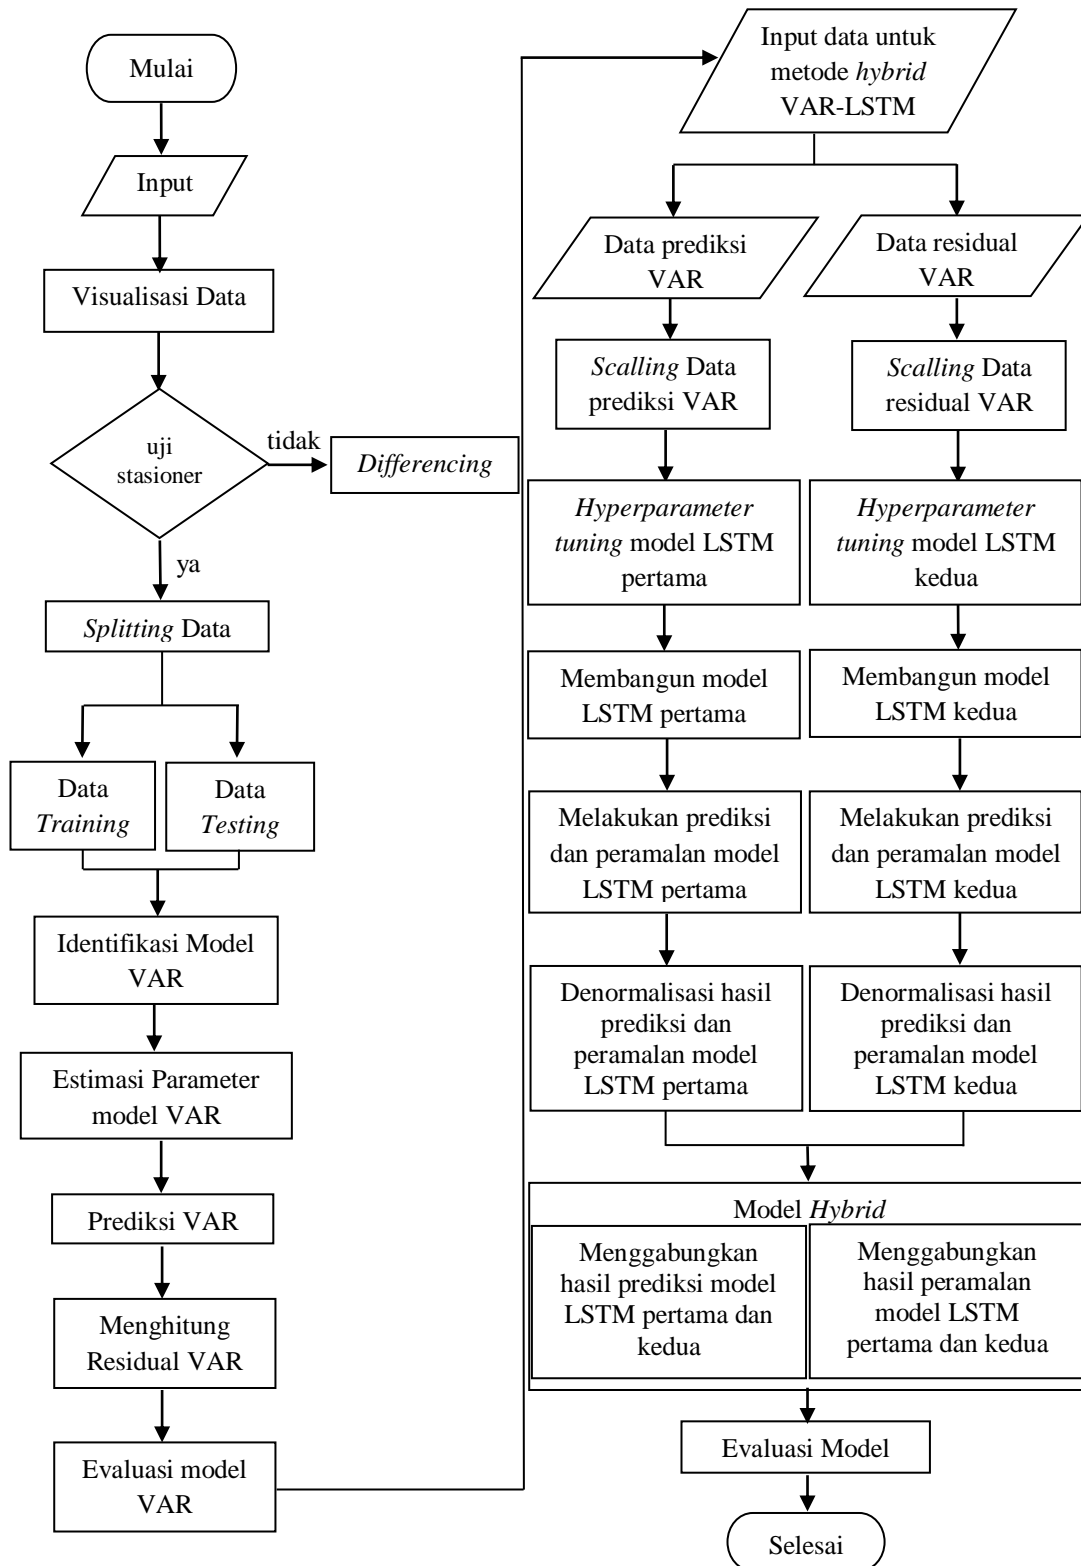
Berikut merupakan alur pengerjaan metode *hybrid* VAR – LSTM :

1. Melakukan studi literatur tentang proses model *hybrid* dari VAR – LSTM yang diambil dari buku, jurnal, dan narasumber yang memahami model tersebut.
2. Mengumpulkan data yang digunakan untuk peramalan.
3. Melakukan *pre-processing* data agar dapat diproses dengan menggunakan metode VAR. Data yang digunakan adalah data pembukaan, tertinggi, terendah, dan penutupan dari mata uang kripto *bitcoin* dan merupakan data historis harian.
4. Melakukan *splitting* data menjadi data *training* dan data *testing* dengan skema 80% data *training* dan 20% data *testing* serta skema 90% data *training* dan 10% data *testing*.
5. Melakukan pembentukan model VAR dengan data *training* dan data *testing* berdasarkan dua skema. Tahapan ini dilakukan dengan mengidentifikasi orde  $p$  dan  $d$  untuk model VAR.



6. Berdasarkan model VAR, kemudian dilakukan prediksi dan peramalan data dari data aktual.
7. Menghitung nilai residual untuk model VAR.
8. Melakukan evaluasi model VAR.
9. Melakukan *input* data prediksi dan data residual dari VAR untuk pengolahan dengan model LSTM.
10. Melakukan normalisasi data prediksi dan data residual VAR dengan menggunakan *min-max scaling*.
11. Menentukan parameter model LSTM pertama dan kedua dengan menggunakan *hyperparameter tuning* dengan metode *grid search*.
12. Membuat dua model utama dengan menggunakan LSTM sebagai landasan dalam proses membangun model *hybrid*. Model LSTM pertama adalah model yang menggunakan data prediksi model VAR sebagai input. Sedangkan, model LSTM kedua adalah model yang menggunakan data residual VAR sebagai inputnya.
13. Melakukan pembentukan model LSTM pertama dan kedua dengan menggunakan *Python* sebagai program pengolah data.
14. Memprediksi dan melakukan peramalan dengan model LSTM pertama menggunakan data prediksi dari VAR.
15. Memprediksi dan melakukan peramalan dengan model LSTM kedua menggunakan data residual dari VAR.
16. Melakukan penggabungan hasil prediksi model LSTM pertama dan kedua dengan proses penjumlahan sebagai hasil prediksi model *hybrid* VAR-LSTM.
17. Melakukan penggabungan hasil peramalan model LSTM pertama dan kedua dengan proses penjumlahan sebagai hasil peramalan model *hybrid* VAR-LSTM.

Berikut merupakan gambar diagram alir peramalan dengan metode *hybrid* VAR-LSTM



Gambar 8. Diagram Alir Proses VAR-LSTM

## V. KESIMPULAN DAN SARAN

### 5.1 KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah diperoleh dapat disimpulkan sebagai berikut :

1. Model yang dibangun dengan metode *hybrid* VAR-LSTM dapat digunakan untuk melakukan peramalan dan prediksi pada data deret waktu yang menunjukkan adanya fluktuasi dari waktu ke waktu seperti pada data *historical* harga bitcoin.
2. Model *hybrid* VAR-LSTM dengan skema 90% data *training* dan 10% data *testing* merupakan model terbaik untuk melakukan prediksi dan peramalan harga *bitcoin* dibandingkan dengan model VAR berdasarkan visualisasi dan nilai MAPE sebesar 0,06.
3. Metode *hybrid* VAR-LSTM dengan skema 90% data *training* dan 10% data *testing* menghasilkan model peramalan dengan hasil terbaik untuk harga *bitcoin* dibandingkan dengan skema lainnya berdasarkan visualisasi dan *p-value* hasil uji  $T^2$  Hotelling sebesar 0,7041.

### 5.2 SARAN

Saran yang dapat penulis berikan untuk pembaca dan penelitian selanjutnya adalah lakukan modifikasi yang sesuai pada parameter model yang digunakan baik parameter VAR ataupun arsitektur LSTM dalam menerapkan metode *hybrid* VAR-LSTM pada jenis data lainnya.

## DAFTAR PUSTAKA

- Adnan, F. N., 2019. Optimasi Peramalan dengan Metode Regresi Weighted Moving Average. *Journal of Information System*. 4(2) : 119-128.
- Afzali, E., Adegoke, A., Jin, Z., Qiu, W., & Wang, L. 2021. Hybrid VAR-LSTM Networks Modeling And Forecasting COVID-19 Data In Canada. *Department of Statistics, University of Manitoba*. 1-10.
- Aji, A. B. & Surjandari, I. 2020. Hybrid Vector Autoregression-Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price. *IOP Conference Series: Materials Science and Engineering*. 909(1) : 1-10.
- Alloghani, M., Al- Jumeily, D., Mustafina, J., & Hussain, A., 2019. *A Systematic Review on Supervised and Unsupervised Machine Learning for Data Science*. In: *Supervised and Unsupervised Learning for Data Science*. s.1. : Springer, p. Chapter 1.
- Blau, B. M. 2018. Price Dynamics and Speculative Trading in Bitcoin. *Reserarch in International Business and Finance*. 43:15-21.
- Brillinger, D. R. 2001. *Time Series: Data Analysis and Theory*. Society for Industrial and Applied Mathematics.
- Budiharto, W. 2016 *Machine learning & computational intelligence*. Penerbit ANDI : Yogyakarta.
- Chen, H., Jiang, L., Luo, Y., Lu, Z., Fu, Y., Li, L., & Yu, Z. 2020. A Cordic-Based Architecture With Adjustable Precision And Flexible Scalability To Implement Sigmoid And Tanh Functions. *IEEE International Symposium on Circuits and Systems (ISCAS)*. 1-5.
- Dissanayake, B., Hemachandra, O., Lakshitha, N., Haputhanthri, D., & Wijayasiri, A. 2021. A Comparison of ARIMAX, VAR, and LSTM on Multivariate Short-Term Traffic Volume Forecasting. *Proceeding of the 28<sup>th</sup> Conference of Fruct Association*. 564-570.

- Engle, R. F., & Granger, C. W. 1987. Co-Integration and Error Correction: Representation, Estimation, and Testing. *Econometrica: journal of the Econometric Society*. **50**(2) : 251-276.
- Enders, W. 2004. *Applied Economic Time Series*. 2<sup>nd</sup> Edition. New York (US) : University of Alabama.
- Febrianti, D. R., Tiro, M. A., & Sudarmin. 2021. Metode Vector Autoregressive (VAR) dalam Menganalisis Pengaruh Kur Mata Uang Terhadap Ekspor dan Impor di Indonesia. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*. **3**(1) : 23 – 30.
- Han, J. & Kember, M. 2006. Data Mining: Concepts and Techniques. *Morgan Kaufmann*. 340 : 94104 – 3205.
- Hanif, T. T., Adiwijaya, A., & Al-Faraby, S. 2017. Analisis Churn Prediction Pada Data Pelanggan Pt. Telekomunikasi Menggunakan Underbagging Dan Logistic Regression. *eProceedings of Engineering*. **4**(2):2310-3225.
- Heizer, J. & Render, B. 2014. *Operations Management: Sustainability and Supply Chain Management*. 11<sup>th</sup> Edition. Pearson Education, Inc.
- Hochreiter, S. & Schmidhuber, J. 1997. Long-Short Term Memory. *Neural Computation*. **9**(8) : 1735-1780.
- Haryatmi, E. & Sheila, P. H. 2021. Penerapan Algoritma Support Vector Machine Untuk Model Prediksi Kelulusan Mahasiswa Tepat Waktu. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*. **5**(2): 386-392.
- Huda, N. & Hambali, R. 2020. Risiko dan Tingkat Keuntungan Investasi Cryptocurrency. *Jurnal Manajemen dan Bisnis: Performa*. **17**(1) : 72-84.
- Isa, I. G. T. & Junedi, B. 2022. Hyperparameter Tuning Epoch dalam Meningkatkan Akurasi Data Latih dan Data Validasi pada Citra Pengendara. *Prosiding Seminar Nasional Sains dan Teknologi*. **12**(1) : 231-237.
- Juanda, R. A., Jondri, & Rohmawati, A. A. 2018. Prediksi Harga Bitcoin Menggunakan Reccurent Neural Network. *E-Proceeding of Engineering*. **5**(2) : 3682-3690.

- Ke, X., Zhao, Y.; Huang, L. 2021. On Accurate Source Enumeration: A New Bayesian Information Criterion. *IEEE Transactions on Signal Processing*. 69: 1012-1027.
- Khoiri. 2021. Cara Menghitung *Exponential Smoothing* di Excel . Januari 2021. <https://www.khoiri.com/2021/01/cara-menghitung-exponential-smoothing.html>. Diakses pada 27 November 2022.
- Makridakis, S., Wheelright, S. C., & McGee, V. E. 1995. *Forecasting : Methods and Applications*. Second Edition. John Wiley and Sons, New Jersey.
- Manaswi, N. K. 2018. *RNN and LSTM. In Deep Learning with Application Using Python*. Apress, Berkeley, CA.
- Mitchell, T. M., 1997. *Machine Learning*. Nee York : McGraw-hill.
- Mohri, M., Sivek, G., & Suresh, A. T. 2019. Agnostic Federated Learning. *Proceedeng of the 36<sup>th</sup> International Conference Machine Learning*. PMLR. 97 : 4615-4625.
- Montgomery, D. C., Jennings, C. L., Murat, K. 2015. *Introduction to Time Series Analysis and Forecating*. John Wiley & Sons.
- Nakamoto, S. 2008. BITCOIN: A peer-to-peer electronic cash system. *Bitcoin.org*. 4(2) : 15.
- Nasution, D. A., Khotimah, H. K., Chamidah, N. 2019. Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *CESS (Journal of Computer Engineering System and Science)*. 4(1):78-82.
- Noorsanti, R. C., Yulianton, H., & Hadiono, K. 2018. Blockchain – Teknologi Mata Uang Kripto ( Crypto Currency). *Prosiding SENDI\_U*. 306-311.
- Ouhame, S. & Hadi, Y. 2019. Multivariate Workload Prediction using VAR and Stacked LSTM models. *Proceeding of the New Challenges in Data Sciens : Acts of the Second Conference of the Morroccan Classification Society*. 10: 1-7
- Owen, M., Vincent, Ambarita, R. B., & Indra, E. 2022. Implementasi Metode Long Short Term Memory untuk Memprediksi Pergerakan Nilai Harga Emas. *Jurnal Tekinkom*. 5(1) : 96-104.

- Pasaribu, D. J. M., Kusriani, & Sudarmawan. 2020. Peningkatan Akurasi Klasifikasi Sentimen Ulasan Makanan Amazon dengan Bidirectional LSTM dan Bert Embedding. *Jurnal Teknologi Informasi dan Komunikasi*. **10**(1) : 9-20.
- Puspasari, S. 2020. Perlindungan Hukum Bagi Investor pada Transaksi Aset Kripto dalam Bursa Berjangka Komoditi. *Jurist-Diction*. **3**(1) : 303-330.
- Rahayu, P. i., Famalika, A., & Sihombing, P. R., 2021. Penerapan Model Vector Autoregressive (VAR(2)) Pada Data Inflasi di Provinsi Jawa Timur dan Bali. *Jurnal Bayesian: Jurnal Ilmiah Statistika dan Ekonometrika*. **1**(1) : 55 – 66
- Rizki, M. I. & Teguh, A. T. 2021. Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Indonesia. *Jurnal Sains dan Statistika*. **7**(2) : 62-72.
- Roihan, A., Sunarya, P. A., & Rafika, A. S. 2020. Pemanfaatan Machine Learning dalam Berbagai Bidang : Review Paper. *IJCIT*. **1**: 75 – 82.
- Saputro, D. R. S., Wigena, A. H., & Djuraidah, A. 2011. Model Vektor Autoregressive Untuk Peramalan Curah Hujan Di Indramayu (Vector Autoregressive Model For Forecast Rainfall In Indramayu). *Forum Statistika dan Komputasi* **16**(2) : 7-11
- Sari, W. K., Rini, D. P., Malik, R. F., & Azhar, I. S. B. 2020. Klasifikasi Teks Multilabel pada Artikel Berita Menggunakan Long Short-Term Memory dengan Word2Vec. *Jurnal Rekayasa Sistem dan Teknologi Informasi*. **4**(2): 276-285.
- Sinha, A., Tayal, R., Vyas, A., Panday, P., & Vyas, O. P. 2021. Forecasting Electricity Load With Hybrid Scalable Model Based on Stacked Non Linear Residual Approach. *Frontiers in Energy Research*. **9** : 682.
- Suntoro, J. 2019. *DATA MINING : Algoritma dan Implementasi dengan Pemrograman php*. Elex Media Komputindo.
- Widarjono, A. 2007. *Ekonometrika : Teori dan Aplikasi untuk Ekonomi dan Bisnis*. Yogyakarta. Ekonisia.
- Wei, W. W. S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. 2<sup>th</sup> edition. Pearson Education, America.

Wei, W. W. S. 2018. *Multivariate Time Series Analysis and Applications*. John Wiley & Sons.

Yu, Y., Si, X., Hu, C., & Zhang, J. 2019. A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*. **31**(7): 1235-1270.

Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50** : 159-175

Zhang, T., Wang, K., & Zhang, X. 2015. Modeling and Analyzing the Transmission Dynamics of HBV Epidemic in Xinjiang, China. *Public Library of Science (PLoS) ONE*. **10**(9): 1-14.