

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE
EXOGENOUS (VARX) – LONG SHORT TERM MEMORY (LSTM)* PADA
PERAMALAN SUKU BUNGA KREDIT INVESTASI**

(Skripsi)

Oleh

NURUL ISNAINI

1917031057



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

ABSTRACT

IMPLEMENTATION OF HYBRID VECTOR AUTOREGRESSIVE EXOGENOUS (VARX) – LONG SHORT TERM MEMORY (LSTM) METHOD IN INVESTMENT LOAN INTEREST RATE FORECASTING

By

NURUL ISNAINI

Investment credit is one of the credits provided by banks for individuals or companies to develop their business. The determination of investment loan interest rates made by banks affects people's interest in making loans. There are several factors that influence banks in setting interest rates, one of which is inflation. The step that can be used to determine the right time to make a loan is to project the value of interest rates in the next few periods. VARX is one of the multivariate statistical methods that can be used for forecasting by involving exogenous variables in it. The VARX method has the disadvantage that it is difficult to capture non-linear patterns in the data. LSTM is a deep learning method that has three types of gates, namely forget gate, input gate, and output gate. The three gates are expected to be able to capture nonlinear patterns in the data. Therefore, the VARX - LSTM hybrid method is used which is expected to be able to predict and forecast. The hybrid method has 2 main models. The first model is a model that predicts the data predicted by VARX. The second model is a model that predicts the residual VARX data. In this study, the VARX - LSTM hybrid model was able to produce an MSE value of 0.02354, RMSE of 0.15342, and MAPE of 0.01349.

Keywords : hybrid VARX – LSTM, VARX, LSTM, forecasting, prediction, investment loan interest rate

ABSTRAK

IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE EXOGENOUS (VARX) – LONG SHORT TERM MEMORY (LSTM)* PADA PERAMALAN SUKU BUNGA KREDIT INVESTASI

Oleh

NURUL ISNAINI

Kredit investasi merupakan salah satu kredit yang diberikan oleh perbankan untuk perorangan atau perusahaan untuk mengembangkan usahanya. Penetapan suku bunga kredit investasi yang dilakukan oleh perbankan berpengaruh pada minat masyarakat dalam melakukan pinjaman. Terdapat beberapa faktor yang mempengaruhi perbankan dalam menetapkan suku bunga, salah satunya yaitu inflasi. Langkah yang dapat digunakan untuk menentukan waktu yang tepat dalam melakukan pinjaman yaitu dengan memproyeksikan nilai suku bunga pada beberapa periode kedepan. VARX merupakan salah satu metode statistika multivariat yang dapat digunakan untuk melakukan peramalan dengan melibatkan variabel eksogen didalamnya. Metode VARX memiliki kelemahan yaitu sulit menangkap pola non-linear pada data. LSTM merupakan metode *deep learning* yang memiliki tiga jenis *gates* yaitu *forget gate*, *input gate*, dan *output gate*. Ketiga *gate* tersebut diharapkan mampu menangkap pola nonlinear pada data. Oleh karena itu, digunakan metode *hybrid VARX – LSTM* yang diharapkan mampu melakukan prediksi dan peramalan. Metode *hybrid* terdapat 2 model utama. Model pertama merupakan model yang memprediksi data hasil prediksi VARX. Model kedua merupakan model yang memprediksi data hasil residual VARX. Pada penelitian ini, model *hybrid VARX – LSTM* mampu menghasilkan nilai MSE sebesar 0,02354, RMSE sebesar 0,15342, dan MAPE sebesar 0,01349.

Kata Kunci : *hybrid VARX – LSTM*, VARX, LSTM, peramalan, prediksi, suku bunga kredit investasi

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE
EXOGENOUS (VARX) – LONG SHORT TERM MEMORY (LSTM)* PADA
PERAMALAN SUKU BUNGA KREDIT INVESTASI**

Oleh

NURUL ISNAINI

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

Judul : **IMPLEMENTASI METODE *HYBRID VECTOR*
AUTOREGRESSIVE EXOGENOUS (VARX) –
LONG SHORT TERM MEMORY (LSTM) PADA
PERAMALAN SUKU BUNGA KREDIT
INVESTASI**

Nama : **Nurul Isnaini**

Nomor Pokok Mahasiswa : **1917031057**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing


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


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


2. Ketua Jurusan Matematika


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

MENGESAHKAN



1. Tim Penguji

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



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

**Penguji
Bukan Pembimbing : Drs. Nusyirwan, M.Si.**



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 : 02 Agustus 2023

PERNYATAAN

Yang bertandatangan di bawah ini :

Nama : Nurul Isnaini

Nomor Pokok Mahasiswa : 1917031057

Jurusan : Matematika

Judul Skripsi : Implementasi Metode *Hybrid Vector Autoregressive Exogenous (VARX) – Long Short Term Memory (LSTM)* pada Peramalan Suku Bunga Kredit Investasi

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

Bandar Lampung, 02 Agustus 2023
Yang Menyatakan,



Nurul Isnaini
NPM. 1917031057

RIWAYAT HIDUP

Penulis bernama lengkap Nurul Isnaini lahir di Purwodadi 27 November 2000. Penulis merupakan putri dari Bapak Jasmin dan Ibu Sriwati. Penulis merupakan anak kedua dari dua bersaudara.

Penulis menempuh pendidikan di TK Al-Istiqomah pada tahun 2005 sampai 2007. Pendidikan sekolah dasar di SD Negeri 1 Purwodadi pada tahun 2007 sampai 2013. Pendidikan menengah pertama di SMP Negeri 1 Kalirejo pada tahun 2013 sampai 2016. Pendidikan menengah atas di SMA Negeri 1 Pringsewu pada tahun 2016 sampai 2019.

Pada tahun 2019 penulis terdaftar sebagai Mahasiswi Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN). Selama menjadi mahasiswi penulis aktif di organisasi sebagai Anggota Bidang Kaderisasi dan Kepemimpinan Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) tahun 2020.

Dalam bentuk pengabdian dan penerapan ilmu kepada masyarakat, penulis melaksanakan Kuliah Kerja Nyata (KKN) yang dilaksanakan pada bulan Januari hingga Februari 2022 di Desa Gaya Baru VII Kecamatan Seputih Surabaya Kabupaten Lampung Tengah. Pada tanggal 20 Juni hingga 29 Juli 2022, penulis melakukan Kerja Praktik (KP) di Badan Pengelola Pajak dan Retribusi Daerah (BPPRD) Kota Bandar Lampung.

KATA INSPIRASI

“Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum hingga mereka mengubah keadaan yang ada pada diri mereka sendiri”

(QS. Al-Rad : 11)

“Karena sesungguhnya sesudah kesulitan ada kemudahan”

(QS. Al-Insyirah : 5)

“Lakukan apa yang harus kamu lakukan sampai kamu dapat melakukan apa yang ingin kamu lakukan”

(Oprah Winfrey)

PERSEMBAHAN

Dengan mengucapkan puji dan syukur kehadiran Allah SWT yang telah memberikan taufik dan hidayah-Nya untuk menyelesaikan skripsi ini, kupersembahkan karya kecil dan sederhana ini kepada :

Bapak dan Mama Tercinta

Yang selalu bekerja dengan keras agar penulis dapat menempuh pendidikan dan mendapat gelar sarjana, yang tidak pernah lelah untuk selalu mendoakan, memberikan dukungan, nasehat dan kasih sayang yang tidak mungkin terbalas oleh apapun.

Kakak Tersayang

Yang telah memberikan semangat, motivasi, doa dan dukungan.

Dosen Pembimbing dan Penguji

Yang senantiasa meluangkan waktu untuk mengarahkan dan memotivasi penulis

Sahabat-sahabatku

Yang selalu memberikan doa, dukungan, motivasi, canda dan tawa yang telah menemani penulis dalam setiap langkahnya

Almamater Tercinta, Universitas Lampung

SANWACANA

Puji dan syukur penulis panjatkan atas kehadiran Allah SWT karena berkat taufik dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Metode *Hybrid Vector Autoregressive Exogenous (VARX) – Long Short Term Memory (LSTM)* pada Peramalan Suku Bunga Kredit Investasi”.

Skripsi ini dibuat sebagai salah satu syarat memperoleh gelar Sarjana Matematika di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung. Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, motivasi, serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu penulis ingin mengucapkan terima kasih kepada :

1. Bapak Ir. Warsono, M.S., Ph.D., selaku Pembimbing I dan Pembimbing Akademik yang selalu bersedia memberikan waktu, arahan, bimbingan, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dian Kurniasari, S.Si., M.Sc., selaku Pembimbing II yang selalu memberikan waktu, ilmu, arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Drs. Nusyirwan, M.Si., selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis.
4. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Kepada kedua orang tua, bapak Jasmin dan ibu Sriwati yang selalu memberikan kasih sayang, doa serta dukungan yang tiada hentinya kepada penulis.
7. Mba Lupi, Mba Ayu dan Mba Retno yang telah memberikan semangat, motivasi, doa, dan dukungan kepada penulis.
8. Odi dan Lana yang telah menghibur dan memberikan semangat kepada penulis.
9. Elka yang telah memberikan semangat, doa, serta dukungan kepada penulis dalam menyelesaikan perkuliahan.
10. Azizah, Neni, Asti, dan Anisa yang selalu memberikan semangat, saran dan menjadi tempat berkeluh kesah penulis.
11. Teman-teman seperjuangan yaitu Silvi, Dea, Irma, dan Fiqih yang selalu berbagi suka duka, saling membantu dan saling memotivasi.
12. Teman-teman Jurusan Matematika Angkatan 2019.
13. Salma, Rony, Nabila, Paul, dan Rayyanza yang telah menghibur, menginspirasi, dan memotivasi penulis melalui karya-karyanya.
14. Semua pihak yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun. Semoga skripsi ini dapat memberikan manfaat bagi pembaca.

Bandar Lampung, 02 Agustus 2023
Penulis

Nurul Isnaini

DAFTAR ISI

	Halaman
DAFTAR TABEL	iii
DAFTAR GAMBAR	iv
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Tujuan Penelitian	4
1.3 Manfaat Penelitian	5
II. TINJAUAN PUSTAKA	6
2.1 Peramalan	6
2.2 <i>Statistical Learning</i>	7
2.3 Model <i>Vector Autoregressive</i> (VAR)	7
2.4 <i>Vector Autoregressive Exogenous</i> (VARX).....	8
2.4.1 Uji Korelasi Data	11
2.4.2 Stasioneritas Data	11
2.4.3 Uji Kausalitas <i>Granger</i>	12
2.4.4 Panjang <i>Lag</i> Optimal	13
2.4.5 Estimasi Parameter Model VARX.....	13
2.4.6 Uji <i>Normalitas</i> Multivariat.....	15
2.4.7 Uji <i>Residual White Noise</i>	16
2.5 <i>Recurrent Neural Network</i> (RNN).....	17
2.6 <i>Long Short Term Memory</i> (LSTM)	18
2.7 Fungsi Aktivasi.....	21
2.8 <i>Scaling Data</i>	23
2.9 <i>Hyperparameter</i>	24
2.10 <i>Hybrid</i> (VARX-LSTM)	25
2.11 Akurasi	27
III. METODOLOGI PENELITIAN	29
3.1 Waktu dan Tempat Penelitian.....	29
3.2 Data Penelitian	29

3.3 Metode Penelitian.....	30
IV. HASIL DAN PEMBAHASAN	33
4.1 <i>Input</i> Data	33
4.2 Prediksi Data dengan VARX.....	34
4.2.1 Uji Stasioneritas Data	35
4.2.2 Uji Kausalitas <i>Granger</i>	36
4.2.3 Penentuan Panjang <i>Lag</i> Optimal	37
4.2.4 Penentuan Orde Model VARX.....	38
4.2.5 Parameter Model VARX.....	39
4.2.6 Hasil Prediksi Model VARX.....	41
4.2.7 Menghitung Data Residual.....	42
4.2.8 Uji Asumsi Normalitas Multivariat	43
4.2.9 Uji Asumsi Residual <i>White Noise</i>	44
4.2.10 Peramalan dengan Model VARX.....	44
4.3 Prediksi Data dengan Model <i>Hybrid</i> VARX – LSTM.....	45
4.3.1 <i>Splitting</i> Data.....	46
4.3.2 <i>Scalling</i> Data	46
4.3.3 Membangun Model Pertama LSTM dengan Prediksi VARX.....	47
4.3.3.1 <i>Hyperparameter Tuning</i> Model Pertama Skema 70% Data <i>Training</i> dan 30% Data <i>Testing</i>	47
4.3.3.2 <i>Hyperparameter Tuning</i> Model Pertama Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	48
4.3.4 Membangun Model Kedua LSTM dengan Residual VARX	49
4.3.4.1 <i>Hyperparameter Tuning</i> Model Kedua Skema 70% Data <i>Training</i> dan 30% Data <i>Testing</i>	50
4.3.4.2 <i>Hyperparameter Tuning</i> Model Kedua Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	51
4.3.5 Prediksi pada Model Pertama LSTM dengan Prediksi VARX ...	52
4.3.6 Prediksi pada Model Kedua LSTM dengan Residual VARX.....	53
4.3.7 Model <i>Hybrid</i>	55
4.4 Peramalan Data dengan Model <i>Hybrid</i> VARX – LSTM	56
4.4.1 Peramalan pada Model Pertama dengan Prediksi VARX.....	57
4.4.2 Peramalan pada Model Kedua dengan Residual VARX	58
4.4.3 Peramalan dengan Model <i>Hybrid</i>	59
V. KESIMPULAN DAN SARAN.....	60
5.1 Kesimpulan.....	60
5.2 Saran.....	61

DAFTAR PUSTAKA

LAMPIRAN

DAFTAR TABEL

Tabel	Halaman
1. Interpretasi nilai korelasi(r).....	11
2. Data Suku Bunga Kredit terhadap Investasi dan Data Inflasi	30
3. Nilai korelasi	34
4. Nilai uji ADF.....	35
5. Nilai uji ADF <i>differencing</i> 1	35
6. Nilai uji ADF <i>differencing</i> 2	36
7. Hasil uji kausalitas <i>granger</i> suku bunga bank persero dan inflasi	36
8. Hasil uji kausalitas <i>granger</i> suku bunga bank umum dan inflasi.....	37
9. Nilai AIC setiap <i>lag</i>	38
10. Model VARX dan nilai AIC	39
11. Parameter – parameter model VARX	39
12. Nilai uji <i>Jarque-Bera</i>	43
13. Nilai uji <i>Ljung-Box</i>	44
14. Jumlah Data <i>Training</i> dan Data <i>Testing</i>	46
15. Hasil <i>hyperparameter tuning</i> model pertama untuk skema 70% data <i>training</i> dan 30% data <i>testing</i>	48
16. Hasil <i>hyperparameter tuning</i> model pertama untuk skema 80% data <i>training</i> dan 20% data <i>testing</i>	49

17.	Hasil <i>hyperparameter tuning</i> model kedua untuk skema 70% data <i>training</i> dan 30% data <i>testing</i>	50
18.	Hasil <i>hyperparameter tuning</i> model kedua untuk skema 80% data <i>training</i> dan 20% data <i>testing</i>	51

DAFTAR GAMBAR

Gambar	Halaman
1. Struktur sel pada LSTM.....	18
2. Grafik Fungsi Sigmoid.....	21
3. Grafik Fungsi Tanh.....	22
4. Grafik Fungsi Linear.....	22
5. <i>Workflow</i> VARX – LSTM	32
6. Plot Data Endogen dan Eksogen	33
7. Plot Prediksi menggunakan Model VARX.....	42
8. Plot Residual menggunakan Model VARX	43
9. Plot peramalan dengan model VARX	45
10. <i>Hyperparameter tuning</i> model pertama untuk skema 70% data <i>training</i> dan 30% data <i>testing</i>	47
11. <i>Hyperparameter tuning</i> model pertama untuk skema 80% data <i>training</i> dan 20% data <i>testing</i>	48
12. <i>Hyperparameter tuning</i> model kedua untuk skema 70% data <i>training</i> dan 30% data <i>testing</i>	50
13. <i>Hyperparameter tuning</i> model kedua untuk skema 80% data <i>training</i> dan 20% data <i>testing</i>	51

14.	Plot Prediksi menggunakan Model Pertama LSTM untuk Skema 70% Data <i>Training</i> dan 30 % Data <i>Testing</i>	52
15.	Plot Prediksi menggunakan Model Pertama LSTM untuk Skema 80% Data <i>Training</i> dan 20 % Data <i>Testing</i>	53
16.	Plot Prediksi menggunakan Model Kedua LSTM untuk Skema 70% Data <i>Training</i> dan 30 % Data <i>Testing</i>	54
17.	Plot Prediksi menggunakan Model Kedua LSTM untuk Skema 80% Data <i>Training</i> dan 20 % Data <i>Testing</i>	54
18.	Plot Prediksi Model <i>Hybrid</i> untuk Skema 70% Data <i>Training</i> dan 30% Data <i>Testing</i>	55
19.	Plot Prediksi Model <i>Hybrid</i> untuk Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	56
20.	Plot Peramalan menggunakan Model Pertama.....	57
21.	Plot Peramalan menggunakan Model Kedua	58
22.	Plot Peramalan menggunakan Model <i>Hybrid</i>	59

I. PENDAHULUAN

1.1. Latar Belakang dan Masalah

Sebagai upaya untuk meningkatkan perekonomian rumah tangga, beberapa masyarakat baik secara perseorangan atau perusahaan memilih untuk mendirikan suatu usaha atau mengembangkan usaha yang telah ada. Kredit investasi merupakan salah satu kredit yang diberikan oleh perbankan untuk perorangan atau perusahaan guna mengembangkan atau memperluas usahanya. Kredit investasi sangat membantu masyarakat dalam mengelola usahanya. Untuk menunjang hal tersebut perbankan akan memberikan suku bunga kredit investasi yang rendah sehingga masyarakat tertarik untuk melakukan kredit investasi. Namun, penetapan suku bunga yang dilakukan oleh perbankan tidak semata-mata agar masyarakat semakin meningkat dalam melakukan pinjaman tetapi perbankan juga mempertimbangkan beberapa faktor dalam penentuannya. Darmawi (2012) menyatakan bahwa terdapat faktor eksternal dan internal yang mempengaruhi perbankan dalam menentukan tingkat suku bunga. Salah satu faktor eksternal yaitu inflasi. Inflasi menggambarkan perubahan harga-harga dalam satuan waktu tertentu. Inflasi biasanya digunakan sebagai ukuran untuk menunjukkan sampai dimana buruknya masalah ekonomi yang dihadapi (Kezia, dkk., 2020).

Peramalan suku bunga kredit adalah analisis yang dapat digunakan sebelum melakukan kredit investasi kepada bank. Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data pada masa kini (Ferry, dkk., 2018). Dalam melakukan analisis peramalan deret waktu terdapat berbagai macam

analisis data yang dapat digunakan. Berdasarkan banyaknya variabel yang digunakan dalam data, analisis data dibedakan menjadi analisis univariat dan multivariat. *Multivariate time series* adalah serangkaian data yang terdiri atas beberapa variabel diambil dari waktu ke waktu dan dicatat secara berurutan menurut waktu kejadiannya dengan interval waktu tertentu (Wei, 2006). Analisis deret waktu multivariat dilakukan apabila menganalisis data dimana terdapat lebih dari satu variabel dependen pada setiap objek yang diamati.

Ada beberapa model analisis deret waktu multivariat, salah satunya yaitu *Vector Autoregressive Exogenous* (VARX). Metode ini merupakan pengembangan dari metode *Vector Autoregressive* (VAR). Berbeda dengan metode VAR yang mendefinisikan bahwa semua peubah yang digunakan merupakan peubah endogen, metode VARX mendefinisikan bahwa terdapat dua peubah yang digunakan, yaitu endogen dan eksogen. Rosyidah, dkk. (2017) menyatakan bahwa model *Vector Autoregressive Exogenous* (VARX) merupakan model deret waktu untuk memodelkan beberapa variabel endogen yang saling berhubungan yang dipengaruhi waktu sebelumnya dan terdapat variabel eksogen yang mempengaruhi variabel endogen tersebut. Model VARX dapat menjelaskan perilaku dinamis dari hubungan antara variabel endogen dan variabel eksogen atau antara variabel endogen saja (Warsono, dkk., 2019). Data suku bunga kredit dan inflasi merupakan contoh data deret waktu multivariat yang dapat diprediksi menggunakan metode VARX dengan suku bunga kredit investasi sebagai variabel endogen dan inflasi sebagai variabel eksogen. Metode VARX memiliki kelemahan yaitu pada data deret waktu dengan pola non-linear akan sulit diprediksi.

Recurrent Neural Network (RNN) merupakan salah satu metode *machine learning* yang dapat digunakan untuk memprediksi data dalam bentuk *time series* dan memiliki akurasi yang cukup baik. *Long Short Term Memory* (LSTM) merupakan metode yang dikembangkan berdasarkan metode RNN, dimana metode tersebut dapat mengekstraksi informasi dari data jangka panjang, *time series* atau *sequensial* (Julian & Pribadi, 2021). LSTM banyak digunakan untuk pemrosesan

teks, video, dan data *time series*. Metode ini pertama kali diperkenalkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997. LSTM menyimpan informasi terhadap pola-pola pada data. LSTM mampu mempelajari data mana yang akan disimpan dan data mana yang akan dibuang, karena pada setiap neuron LSTM memiliki beberapa *gates* yang mengatur memori pada setiap neuron itu sendiri (Aldi, dkk., 2018).

Pengembangan model prediksi berdasarkan model VARX dan model LSTM yaitu model *hybrid* VARX-LSTM. Model VARX diekspresikan sebagai kombinasi linear dari pengamatan masa lalu terhadap dirinya sendiri dan variabel lain. Disisi lain, metode LSTM mampu menangkap pola non linear (Caliwag & Lim, 2019). Kombinasi kedua model tersebut digunakan untuk mengatasi kelemahan metode VARX dan LSTM secara independen. Sehingga, kombinasi antara model VARX dan LSTM diharapkan dapat memaksimalkan nilai akurasi yang dihasilkan.

Hasil yang diperoleh pada proses prediksi belum tentu sesuai dengan data aktualnya. Selisih dari hasil peramalan dengan data aktual biasa disebut dengan *error* atau *residual*. Rosyidah, dkk. (2017) menyatakan bahwa kemampuan model dalam melakukan peramalan bisa dilihat dari hasil perhitungan ketepatan peramalan. Alat ukur yang dapat digunakan untuk mengukur tingkat ketepatan peramalan atau tingkat akurasi hasil peramalan yaitu *Mean Absolute Percentage Error* (MAPE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE).

Beberapa penelitian yang telah dilakukan adalah Halimatuzzahro & Lestari (2021) mengenai peramalan suku bunga kredit rupiah modal kerja pada bank swasta nasional di Indonesia menggunakan model ARIMA menghasilkan nilai MSE yang sangat kecil, yaitu 0,0000017. Penelitian lainnya dilakukan oleh Salsabila, dkk. (2022) mengenai peramalan ekspor dan impor total di Indonesia menggunakan model VARX memberikan hasil peramalan yang baik dengan MAPE ekspor 5,938% dan impor 8,313%. Penelitian menggunakan metode VARX lainnya

dilakukan oleh Warsono, dkk. (2019) mengenai pemodelan dan peramalan data energi yang menghasilkan prediksi sangat baik. Penelitian yang dilakukan oleh Ulumuddin, dkk. (2020) mengenai prediksi harga bitcoin menggunakan LSTM yang menghasilkan prediksi dengan akurasi 97,48%. Penelitian lainnya dilakukan oleh Akbar, dkk. (2022) mengenai prediksi tingkat temperatur kota Semarang menggunakan metode LSTM dengan nilai MAPE sebesar 1,896016% atau dapat dikatakan model LSTM yang digunakan mampu melakukan prediksi dengan baik.

Sedangkan penelitian mengenai metode *hybrid* telah dilakukan oleh Dave, dkk. (2021) mengenai peramalan ekspor Indonesia menggunakan model *hybrid* ARIMA – LSTM yang menghasilkan nilai akurasi prediksi yaitu MSE sebesar $2,77e-26$ dan MAPE sebesar 7,38%. Penelitian metode *hybrid* lainnya dilakukan oleh Rambha & Seshashayee (2022) mengenai prediksi kualitas udara menggunakan metode *hybrid* VAR – LSTM yang menghasilkan MSE sebesar 6,932. Penelitian model *hybrid* lainnya dilakukan oleh Caliwag & Lim (2019) mengenai metode *hybrid* VARMA dan LSTM untuk keamanan baterai lithium-ion dan peramalan tegangan keluaran pada aplikasi sepeda motor listrik yang menghasilkan kombinasi metode VARMA – LSTM memiliki nilai RMSE yang lebih kecil dibandingkan metode VARMA atau LSTM sendiri.

Berdasarkan uraian di atas, penulis tertarik untuk melakukan penelitian mengenai keefektifan metode *hybrid* VARX-LSTM dan melakukan peramalan suku bunga kredit terhadap investasi sehingga dapat digunakan untuk calon nasabah dalam mengambil keputusan untuk melakukan kredit investasi terhadap bank.

1.2. Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui kinerja model dari metode *hybrid* VARX – LSTM terhadap suku bunga kredit investasi.

2. Mengetahui peramalan suku bunga kredit investasi dengan menggunakan metode *hybrid* VARX – LSTM.

1.3. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Memberikan pengetahuan mengenai pemodelan dan peramalan suku bunga kredit investasi.
2. Memberikan pengetahuan mengenai metode *hybrid* VARX – LSTM.
3. Sebagai sumber ilmu pengetahuan bagi penulis dan pembaca.

II. TINJAUAN PUSTAKA

2.1 Peramalan

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai ada masa yang akan datang dengan memperhatikan data masa lalu maupun data pada masa kini (Ferry, dkk., 2018). Montgomery, dkk. (2015) berpendapat bahwa peramalan adalah masalah penting yang mencakup banyak bidang, termasuk bisnis dan industri, pemerintah, ekonomi, ilmu lingkungan, kedokteran, ilmu sosial, politik, dan keuangan. Dalam proses peramalan digunakan data masa lalu yang relevan dan diproyeksikan untuk masa depan dengan menggunakan model matematika.

Montgomery, dkk. (2015) mengatakan bahwa meskipun berbagai situasi masalah yang memerlukan peramalan, hanya ada dua jenis teknik peramalan, yaitu:

1. Peramalan kualitatif merupakan peramalan yang didasarkan atas data kualitatif pada masa lalu. Hasil dari peramalan ini bergantung pada orang yang menyusunnya.
2. Peramalan kuantitatif merupakan peramalan yang menggunakan data kuantitatif pada masa lalu. Hasil dari peramalan ini bergantung pada metode yang digunakan.

2.2 *Statistical Learning*

Statistika mempunyai peranan sangat penting bagi perkembangan ilmu-ilmu lain guna mengambil kesimpulan, melakukan pengujian hipotesis atau teori, menentukan keputusan, dan lain sebagainya. *Machine learning* atau pembelajaran mesin yang merupakan salah satu cabang dari *Artificial Intelligence* (AI) atau kecerdasan buatan terus mengalami perkembangan. Perkembangan ilmu statistika dan *machine learning* tidak lepas dari faktor utamanya, yaitu data.

Statistical learning adalah bidang yang baru-baru ini dikembangkan dalam statistik dan perkembangan ilmu komputer, khususnya *machine learning*. James, dkk. (2013) berpendapat bahwa *statistical learning* mengacu pada seperangkat alat yang luas untuk memahami data. Alat tersebut dapat diklasifikasikan menjadi dua kategori, yaitu *supervised learning* dan *unsupervised learning*.

1. *Supervised learning*

Supervised learning merupakan algoritma *machine learning* yang menggunakan data-data yang sudah diberi label atau datasetnya sudah dikenal. Data-data tersebut diharapkan dapat melatih (*supervise*) algoritma untuk prediksi atau klasifikasi suatu kasus dengan akurat.

2. *Unsupervised learning*

Unsupervised learning merupakan algoritma *machine learning* dengan tidak memberikan data label atau informasi dari outputnya. Algoritma tersebut akan menentukan pola yang mungkin didapat dari suatu data.

2.3 Model *Vector Autoregressive* (VAR)

Model *Vector Autoregressive* (VAR) adalah gabungan dari beberapa model *autoregressive* (AR) yang merupakan univariat time series menjadi multivariat time series yang memiliki lebih dari satu variabel endogen. Model VAR

dilakukan untuk memodelkan beberapa variabel endogen secara bersamaan. Setiap variabel endogen dijelaskan oleh nilai-nilai *lagged* atau masa lalu dan nilai-nilai *lagged* dari semua variabel endogen lainnya dalam model, dan biasanya tidak terdapat variabel eksogen dalam model (Gujarati, 2004). Secara umum, model VAR(p) dapat ditulis sebagai berikut:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.5)$$

dengan :

- Y_t = vektor berukuran $n \times 1$ berisi n variabel endogen pada waktu t dan $t - i, i = 1, 2, \dots, p$
- α = vektor konstanta berukuran $n \times 1$
- ϕ_i = matriks parameter variabel endogen berukuran $n \times n$
- ε_t = vektor galat berukuran $n \times 1$
- $\varepsilon_t \sim N_p(0, \Sigma)$

Model VAR(1) yang terdiri dari 2 variabel dapat ditulis:

$$\begin{aligned} Y_{1,t} &= \alpha_1 + \phi_{11} Y_{1,t-1} + \phi_{12} Y_{2,t-1} + \varepsilon_{1,t} \\ Y_{2,t} &= \alpha_2 + \phi_{21} Y_{1,t-1} + \phi_{22} Y_{2,t-1} + \varepsilon_{2,t} \end{aligned} \quad (2.6)$$

Bentuk matriksnya adalah sebagai berikut:

$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_2 \end{bmatrix} + \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \end{bmatrix} \quad (2.7)$$

2.4 Vector Autoregressive Exogenous (VARX)

VARX adalah singkatan dari *Vector Autoregressive Exogenous*. Model *Vector Autoregressive Exogenous* (VARX) merupakan pengembangan dari model *Vector Autoregressive* (VAR) dengan penambahan peubah eksogen di dalam model. VARX berupa metode analisis runtun waktu multivariat yang digunakan untuk menjelaskan perubahan data serta hubungan timbal balik antara variabel eksogen

dan endogen (Ferry, dkk., 2018). Prahutama, dkk. (2019) mengatakan bahwa, model VARX dinyatakan dengan dua orde p dan s , dengan p merupakan orde variabel endogen sedangkan s merupakan orde variabel eksogen. Prosedur VARX dapat digunakan untuk mencari pemodelan. Model ini termasuk pada bentuk persamaan simultan. Berikut merupakan bentuk umum dari model VARX.

$$\mathbf{Y}_t = \alpha + \phi_1 \mathbf{Y}_{t-1} + \dots + \phi_p \mathbf{Y}_{t-p} + \theta_1 \mathbf{X}_{t-1} + \dots + \theta_s \mathbf{X}_{t-s} + \boldsymbol{\varepsilon}_t \quad (2.8)$$

dengan :

\mathbf{Y}_t = vektor berukuran $n \times 1$ berisi n variabel endogen pada waktu t dan $t - i, i = 1, 2, \dots, p$

α = vektor konstanta berukuran $n \times 1$

ϕ_i = matriks parameter variabel endogen berukuran $n \times n$

\mathbf{X}_{t-j} = vektor variabel eksogen pada waktu $t - j, j = 1, 2, \dots, s$

θ_j = matriks parameter variabel eksogen berukuran $n \times s$

$\boldsymbol{\varepsilon}_t$ = vektor galat berukuran $n \times 1$

$\boldsymbol{\varepsilon}_t \sim N_p(0, \Sigma)$

p = lag variabel endogen

s = lag variabel eksogen

Persamaan model VARX(p, s) yang terdiri dari n variabel endogen dan m variabel eksogen dapat ditulis:

$$\begin{aligned} Y_{1,t} &= \alpha_1 + \phi_{11} Y_{1,t-1} + \dots + \phi_{1n} Y_{n,t-p} + \theta_{11} X_{1,t-1} + \dots + \theta_{1m} X_{m,t-s} + \varepsilon_{1,t} \\ Y_{2,t} &= \alpha_2 + \phi_{21} Y_{1,t-1} + \dots + \phi_{2n} Y_{n,t-p} + \theta_{21} X_{1,t-1} + \dots + \theta_{2m} X_{m,t-s} + \varepsilon_{2,t} \\ &\vdots \\ Y_{n,t} &= \alpha_n + \phi_{n1} Y_{1,t-1} + \dots + \phi_{nn} Y_{n,t-p} + \theta_{n1} X_{1,t-1} + \dots + \theta_{nm} X_{m,t-s} + \varepsilon_{n,t} \end{aligned} \quad (2.9)$$

Bentuk matriksnya adalah sebagai berikut:

$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ \vdots \\ Y_{n,t} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_n \end{bmatrix} + \begin{bmatrix} \phi_{11(1)} & \phi_{12(1)} & \dots & \phi_{1n(1)} \\ \phi_{21(1)} & \phi_{22(1)} & \dots & \phi_{2n(1)} \\ \vdots & \vdots & \dots & \vdots \\ \phi_{n1(1)} & \phi_{n2(1)} & \dots & \phi_{nn(1)} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ \vdots \\ Y_{n,t-1} \end{bmatrix} + \dots +$$

$$\begin{aligned}
& \begin{bmatrix} \phi_{11(p)} & \phi_{12(p)} & \cdots & \phi_{1n(p)} \\ \phi_{21(p)} & \phi_{22(p)} & \cdots & \phi_{2n(p)} \\ \vdots & \vdots & \cdots & \vdots \\ \phi_{n1(p)} & \phi_{n2(p)} & \cdots & \phi_{nn(p)} \end{bmatrix} \begin{bmatrix} Y_{1,t-p} \\ Y_{2,t-p} \\ \vdots \\ Y_{n,t-p} \end{bmatrix} + \\
& \begin{bmatrix} \theta_{11(1)} & \theta_{12(1)} & \cdots & \theta_{1m(1)} \\ \theta_{21(1)} & \theta_{22(1)} & \cdots & \theta_{2m(1)} \\ \vdots & \vdots & \cdots & \vdots \\ \theta_{n1(1)} & \theta_{n2(1)} & \cdots & \theta_{nm(1)} \end{bmatrix} \begin{bmatrix} X_{1,t-1} \\ X_{2,t-1} \\ \vdots \\ X_{m,t-1} \end{bmatrix} + \cdots + \\
& \begin{bmatrix} \theta_{11(s)} & \theta_{12(s)} & \cdots & \theta_{1m(s)} \\ \theta_{21(s)} & \theta_{22(s)} & \cdots & \theta_{2m(s)} \\ \vdots & \vdots & \cdots & \vdots \\ \theta_{n1(s)} & \theta_{n2(s)} & \cdots & \theta_{nm(s)} \end{bmatrix} \begin{bmatrix} X_{1,t-s} \\ X_{2,t-s} \\ \vdots \\ X_{m,t-s} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \vdots \\ \varepsilon_{n,t} \end{bmatrix}
\end{aligned} \tag{2.10}$$

dengan :

- $Y_{k,t}$ = variabel endogen ke – k pada waktu t dengan $k = 1, 2, \dots, n$
- $Y_{k,t-i}$ = variabel endogen ke – k pada waktu $t - i$ dengan $k = 1, 2, \dots, n$
dan $i = 1, 2, \dots, p$
- $X_{l,t-j}$ = variabel eksogen ke – l pada waktu $t - j$ dengan $l = 1, 2, \dots, m$
dan $j = 1, 2, \dots, s$
- α_k = konstanta persamaan variabel endogen ke – k dengan
 $k = 1, 2, \dots, n$
- $\phi_{kk(i)}$ = koefisien parameter persamaan variabel endogen ke – k untuk
variabel ke – k pada lag i dengan $i = 1, 2, \dots, p$
- $\theta_{ll(j)}$ = koefisien parameter persamaan variabel eksogen ke – l untuk
variabel ke – l pada lag j dengan $i = 1, 2, \dots, s$
- $\varepsilon_{k,t}$ = residual variabel endogen ke – k pada waktu t dengan
 $k = 1, 2, \dots, n$
- $\varepsilon_{k,t} \sim N_p(0, \Sigma)$
- p = lag variabel endogen
- s = lag variabel eksogen

2.4.1 Uji Korelasi Data

Uji korelasi digunakan untuk menentukan suatu besaran yang menyatakan seberapa kuat hubungan suatu variabel dengan variabel lain. Sedangkan koefisien korelasi (r) digunakan untuk mengetahui derajat hubungan antar variabel-variabel (Jabnabillah & Margina, 2022). Pengujian korelasi data dapat dilakukan dengan menggunakan uji korelasi pearson. Rumus uji korelasi pearson adalah sebagai berikut :

$$r = \frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n X_i \cdot \sum_{i=1}^n Y_i}{\sqrt{(n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2)(n \sum_{i=1}^n Y_i^2 - (\sum_{i=1}^n Y_i)^2)}} \quad (2.11)$$

Berikut adalah interpretasi dari nilai korelasi (r) (Supriadi, 2021):

Tabel 1. Interpretasi nilai korelasi(r)

Nilai korelasi (r)	Interpretasi
0,00 – 0,199	Sangat Rendah
0,20 – 0,399	Rendah
0,40 – 0,599	Cukup
0,60 – 0,799	Kuat
0,80 – 1,000	Sangat Kuat

2.4.2 Stasioneritas Data

Dalam *time series* asumsi yang sangat penting adalah stasioneritas data. Suatu data dikatakan stasioner apabila tidak terjadi perubahan yang signifikan pada data. Fluktuasi data berada disekitar nilai rata-rata yang konstan, homogen dari waktu ke waktu, dan varians dari fluktuasi tersebut pada dasarnya tetap konstan setiap waktu (Agustin, dkk., 2019). Pengujian stasioneritas data dapat dilakukan dengan

menggunakan *Augmented Dickey-Fuller test* (ADF test). Rumus uji ADF adalah sebagai berikut:

$$ADF_{hitung} = \frac{\hat{\phi} - 1}{SE(\hat{\phi})} \quad (2.12)$$

dimana $\hat{\phi}$ merupakan nilai dugaan parameter *Autoregressive* (AR) dengan orde p dan $SE(\hat{\phi})$ merupakan *standard error*. Hipotesis yang digunakan yaitu:

H_0 : data tidak stasioner

H_1 : data stasioner

Pengambilan keputusan uji ADF yaitu jika nilai $ADF_{hitung} > ADF_{tabel}$ atau $p - value < \alpha$ maka tolak H_0 yang artinya data stasioner.

Apabila data asli tidak memenuhi kestasioneran data, maka perlu dilakukan proses *differencing*. *Differencing* merupakan menghitung perubahan atau selisih nilai observasi. Proses *differencing* bisa dilakukan beberapa kali yang biasanya disebut dengan *differencing* orde ke- d , sehingga bila melakukan *differencing* satu kali maka disebut *differencing* orde ke-1 dan seterusnya. Apabila belum stasioner maka dilakukan *differencing* lagi sampai memperoleh data yang stasioner. Berikut merupakan proses *differencing*:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2.13)$$

dengan :

ΔY_t = *differencing* data

Y_t = data periode saat ini

Y_{t-1} = data periode sebelumnya

2.4.3 Uji Kausalitas *Granger*

Kausalitas adalah hubungan dua arah. Ferry, dkk. (2018) mengatakan bahwa kausalitas *granger* merupakan salah satu langkah untuk mengetahui hubungan antara variabel satu dengan variabel yang lain. Misalkan terdapat dua peubah X dan Y maka terdapat beberapa kemungkinan yang dapat terjadi, antara lain:

- a. X menyebabkan Y
- b. Y menyebabkan X
- c. X menyebabkan Y dan Y menyebabkan X
- d. X dan Y tidak memiliki hubungan.

2.4.4 Panjang *Lag* Optimal

Agustin, dkk. (2019) mengatakan bahwa *lag* optimal diperlukan untuk mengetahui pengaruh dari setiap peubah terhadap peubah lainnya. Penentuan panjang *lag* optimal pada model VARX digunakan untuk menentukan orde p dari VAR. Panjang *lag* optimal dapat ditentukan dengan menggunakan nilai kriteria yang biasa digunakan yaitu *Akaike Information Criteria* (AIC). Panjang *lag* optimal dapat ditentukan dengan melihat nilai AIC terkecil kemudian dapat menentukan model terbaik dari model-model yang memungkinkan. Berikut merupakan rumus AIC (Wei, 2006):

$$AIC(p) = \ln|\Sigma(p)| + \frac{2m^2h}{n} \quad (2.14)$$

dengan:

- $|\Sigma(p)|$ = determinan matriks kovarian residual model VAR(p)
- n = banyaknya pengamatan
- h = panjang *lag*
- m = banyaknya variabel endogen dalam model

2.4.5 Estimasi Parameter Model VARX

Estimasi parameter model VARX menggunakan metode kuadrat terkecil dengan cara mengkuadratkan error agar diperoleh error minimum (Rosyidah, dkk., 2017). Persamaan umum model VARX dalam persamaan (2.8) dapat diubah ke dalam bentuk matriks sebagai berikut:

$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ \vdots \\ Y_{n,t} \end{bmatrix} = \begin{bmatrix} 1 & Y_{1,t-1} & \cdots & Y_{1,t-p} & X_{1,t-1} & \cdots & X_{1,t-s} \\ 1 & Y_{2,t-1} & \cdots & Y_{2,t-p} & X_{2,t-1} & \cdots & X_{2,t-s} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 1 & Y_{n,t-1} & \cdots & Y_{n,t-p} & X_{n,t-1} & \cdots & X_{n,t-s} \end{bmatrix} \begin{bmatrix} \alpha \\ \phi_1 \\ \vdots \\ \phi_p \\ \theta_1 \\ \vdots \\ \theta_s \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \vdots \\ \varepsilon_{n,t} \end{bmatrix} \quad (2.15)$$

dengan :

$$Y = \begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ \vdots \\ Y_{n,t} \end{bmatrix}_{n \times 1}$$

$$X = \begin{bmatrix} 1 & Y_{1,t-1} & \cdots & Y_{1,t-p} & X_{1,t-1} & \cdots & X_{1,t-s} \\ 1 & Y_{2,t-1} & \cdots & Y_{2,t-p} & X_{2,t-1} & \cdots & X_{2,t-s} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 1 & Y_{n,t-1} & \cdots & Y_{n,t-p} & X_{n,t-1} & \cdots & X_{n,t-s} \end{bmatrix}_{n \times (p+s+1)}$$

$$\beta = \begin{bmatrix} \alpha \\ \phi_1 \\ \vdots \\ \phi_p \\ \theta_1 \\ \vdots \\ \theta_s \end{bmatrix}_{(p+s+1) \times 1}$$

$$\varepsilon = \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \vdots \\ \varepsilon_{n,t} \end{bmatrix}_{n \times 1}$$

Sehingga diperoleh persamaan:

$$Y = X\beta + \varepsilon \quad (2.16)$$

Persamaan (2.17) dapat diubah menjadi:

$$\varepsilon = Y - X\beta \quad (2.17)$$

Pendugaan parameternya dimisalkan menjadi:

$$E = Y - X\hat{\beta} \quad (2.18)$$

Dimana E adalah matriks berukuran $n \times 1$ sebagai berikut:

$$E = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_{n \times 1}$$

Misalkan, jumlah kuadrat errornya:

$$\begin{aligned}
 SSE &= \sum_{i=1}^n e_i^2 = E^t E \\
 SSE &= E^t E \\
 &= (Y - X\hat{\beta})^t (Y - X\hat{\beta}) \\
 &= Y^t Y - Y^t X\hat{\beta} - (X\hat{\beta})^t Y + (X\hat{\beta})^t X\hat{\beta} \\
 &= Y^t Y - (Y^t X\hat{\beta})^t - \hat{\beta}^t X^t Y + \hat{\beta}^t X^t X\hat{\beta} \\
 &= Y^t Y - \hat{\beta}^t X^t Y - \hat{\beta}^t X^t Y + \hat{\beta}^t X^t X\hat{\beta} \\
 &= Y^t Y - 2\hat{\beta}^t X^t Y + \hat{\beta}^t X^t X\hat{\beta}
 \end{aligned} \tag{2.19}$$

SSE minimum diperoleh jika turunannya bernilai 0. Oleh karena itu, persamaan (2.10) diturunkan terhadap penduga parameternya, menjadi:

$$\begin{aligned}
 \frac{\partial SSE}{\partial \hat{\beta}} &= 0 \\
 \frac{\partial}{\partial \hat{\beta}} (Y^t Y - 2\hat{\beta}^t X^t Y + \hat{\beta}^t X^t X\hat{\beta}) &= 0 \\
 -2X^t Y + 2X^t X\hat{\beta} &= 0 \\
 2X^t X\hat{\beta} &= 2X^t Y \\
 X^t X\hat{\beta} &= X^t Y \\
 \hat{\beta} &= (X^t X)^{-1} X^t Y
 \end{aligned} \tag{2.20}$$

Maka nilai estimasi parameter untuk β adalah $\hat{\beta} = (X^t X)^{-1} X^t Y$

2.4.6 Uji Normalitas Multivariat

Pengujian residual terhadap asumsi ini dilakukan untuk mengetahui residual mengikuti distribusi normal multivariat atau tidak. Uji normalitas dapat dicapai dengan memeriksa apakah fungsi kerapatan (*density function*) bernilai nol untuk semua frekuensi (Wei, 2006). Berdasarkan *Central Limit Theorem* (CLT) bahwa distribusi sampel berukuran n dari suatu distribusi populasi yang memiliki μ tertentu dan σ^2 tertentu, akan berbentuk normal $\sim N(0,1)$ apabila $n \rightarrow \infty$ (Hogg, dkk., 1977). Dengan kata lain, semakin banyak jumlah sampel maka penyebaran

sampel akan semakin berbentuk normal. Uji normalitas multivariat dapat dilakukan dengan menggunakan *Jarque-Bera Test of Normality* sebagai berikut:

1. Hipotesis:

H_0 : data residual berdistribusi normal

H_1 : data residual tidak berdistribusi normal

2. Taraf signifikansi

$\alpha = 5\% = 0,05$

3. Kriteria uji:

- Tolak H_0 jika $JB_{hitung} > X_{tabel}^2$ atau $p\text{-value} < \alpha$
- Tidak tolak H_0 jika $JB_{hitung} < X_{tabel}^2$ atau $p\text{-value} > \alpha$

4. Statistik uji:

$$JB_{hitung} = \left[\frac{N}{6} b_1^2 + \frac{N}{24} (b_2 - 3)^2 \right] \quad (2.21)$$

dengan :

n = banyaknya data pengamatan

b = *expected skewness*

5. Keputusan

6. Kesimpulan

2.4.7 Uji Residual *White Noise*

Residual bersifat *white noise* artinya tidak ada korelasi dari vektor residual dalam model hingga *lag* ke h (Rosyidah, dkk., 2017). Uji residual *white noise* dapat dilakukan dengan menggunakan statistik uji *Ljung-Box* sebagai berikut:

1. Hipotesis:

H_0 : tidak ada korelasi dari residual (residual memenuhi asumsi *white noise*)

H_1 : ada korelasi dari residual (residual tidak memenuhi asumsi *white noise*)

2. Taraf signifikansi

$$\alpha = 5\% = 0,05$$

3. Kriteria uji:

- Tolak H_0 jika $Q_{hitung} > X_{tabel}^2$ atau $p\text{-value} < \alpha$
- Tidak tolak H_0 jika $Q_{hitung} < X_{tabel}^2$ atau $p\text{-value} > \alpha$

4. Statistik uji:

$$Q_{hitung} = n(n + 2) \sum_{i=1}^{n/4} \frac{\hat{\rho}_i^2}{(n - i)} \quad (2.22)$$

dengan :

n = banyaknya data pengamatan

$\hat{\rho}_i$ = dugaan ACF residual pada periode *lag* ke- i

5. Keputusan


6. Kesimpulan

2.5 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) merupakan salah satu bentuk *Artificial Neural Network* (ANN) untuk memproses data yang berurutan / bersambung (*sequential data*). RNN mampu menyimpan memori yang memungkinkan untuk mengenali pola data dengan baik, kemudian digunakan untuk membuat prediksi yang akurat. Struktur yang dimiliki RNN yaitu *input layer*, *hidden layer*, dan *output layer*. Dalam RNN, lapisan berulang / *hidden layer* terdiri dari sel-sel berulang yang statusnya dipengaruhi oleh status masa lalu dan data input saat ini (Yu, dkk., 2019). Namun, RNN tidak dapat mengingat informasi sebelumnya dengan baik ketika interval waktunya panjang karena masalah hilangnya gradien (Tian, dkk., 2018). Pada dasarnya model RNN memiliki satu arah aliran informasi dari unit input ke unit tersembunyi, dan sintesis aliran informasi satu arah dari unit tersembunyi sementara sebelum ke unit tersembunyi saat ini (Yin, dkk., 2017).

2.6 Long Short Term Memory (LSTM)

Long Short Term Memory adalah salah satu modifikasi dari *Recurrent Neural Network* (RNN). Hochreiter & Schmidhuber mengusulkan LSTM pada tahun 1997. LSTM hadir untuk melengkapi kekurangan RNN yang tidak mampu memproses data jangka panjang. LSTM menggabungkan memori jangka pendek dengan memori jangka panjang melalui kontrol gerbang (Tian, dkk., 2018). LSTM dapat mempelajari dependensi jangka panjang karena penggunaan mekanisme gerbang dan sel memori (Fadli, dkk., 2022). Dalam LSTM terdapat tiga jenis *gates* yaitu *forget gate*, *input gate*, dan *output gate*. Masing-masing *gate* memiliki peran untuk melindungi dan mengontrol *cell state*. *Cell state* merupakan garis horizontal yang menghubungkan semua *output layer* pada LSTM. LSTM biasa digunakan untuk memproses, memprediksi, dan mengklasifikasikan informasi berdasarkan data deret waktu.



Gambar 1. Struktur sel pada LSTM (Sumber: Chung & Shin, 2018)

Forget gate merupakan gerbang pertama yang dioperasikan dalam sel LSTM. *Forget gate* berfungsi untuk menentukan informasi yang harus di pertahankan dan yang harus dibuang dari *cell state*. Gerbang ini menerima 2 *input*, yaitu h_{t-1} yang merupakan keluaran pada proses LSTM pada waktu sebelumnya dan x_t yang merupakan input pada waktu saat ini. Output dari gerbang ini adalah angka dengan rentang 0 hingga 1. Untuk angka 1 merepresentasikan “sepenuhnya simpan” dan angka 0 merepresentasikan “sepenuhnya buang”.

Rumus yang digunakan pada *forget gate* yaitu

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] b_f) \quad (2.23)$$

dengan :

- f_t = *forget gate*
- σ = fungsi sigmoid
- W_f = bobot pada *forget gate*
- h_{t-1} = hasil output pada *time step* $t - 1$
- x_t = input pada *time step* t
- b_f = bias pada *forget gate*

Setelah mendapatkan nilai pada rentang 0 hingga 1 pada *forget gate*, kemudian dilanjutkan ke *input gate*. *Input gate* terdiri dari dua bagian, bagian pertama menggunakan fungsi sigmoid untuk menentukan nilai yang akan diperbaharui. Sedangkan bagian kedua menggunakan fungsi tanh untuk menentukan vektor yang akan ditambahkan pada *cell state* (C'_t). Kedua bagian tersebut akan digabungkan untuk menentukan pembaruan informasi pada *cell state*.

Rumus yang digunakan pada *input gate* yaitu

$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] b_i) \quad (2.24)$$

$$C'_t = \tanh (W_c \cdot [h_{t-1}, x_t] b_c) \quad (2.25)$$

dengan :

- i_t = *input gate*
- σ = fungsi sigmoid
- W_i = bobot pada *input gate*
- h_{t-1} = hasil output pada *time step* $t - 1$
- x_t = input pada *time step* t
- b_i = bias pada *input gate*
- C'_t = kandidat nilai *cell state* baru yang akan ditambahkan ke C_{t-1}
- \tanh = fungsi tanh
- W_c = bobot pada operasi *cell state* baru
- b_c = bias pada operasi *cell state* baru

Hasil dari *forget gate* dan *input gate* kemudian dioperasikan agar hasil dari operasi tersebut dapat digunakan untuk menentukan pembaruan pada *cell state* baru (C_t). Pada operasi ini dilakukan perkalian antara *cell state* (C_{t-1}) dengan hasil *forget gate* (f_t) lalu ditambahkan dengan hasil perkalian antara *input gate* (i_t) dengan nilai *cell state* baru pada hasil perhitungan *input gate* (C'_t).

Rumus yang digunakan pada operasi ini yaitu

$$C_t = f_t * C_{t-1} + i_t * C'_t \quad (2.26)$$

dengan :

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

f_t = *forget gate*

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

i_t = *input gate*

C'_t = nilai *cell state* baru pada hasil perhitungan *input gate*

Langkah selanjutnya adalah mengoperasikan *output gate*. Pada *output gate*, layer sigmoid akan diperasikan terlebih dahulu untuk menentukan bagian dari *cell state* yang akan dihasilkan. Kemudian operasi tanh dijalankan pada *cell state* lalu dikalikan dengan hasil dari layer sigmoid yang telah dihitung sebelumnya, sehingga mendapatkan keluaran akhir.

Rumus yang digunakan pada *output gate* yaitu

$$o_t = \sigma (W_o \cdot [h_{t-1} , x_t] b_o) \quad (2.27)$$

$$h_t = o_t * \tanh (C_t) \quad (2.28)$$

dengan :

o_t = *output gate*

σ = fungsi sigmoid

W_o = bobot pada *output gate*

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

x_t = *input* pada *time step* t

b_o = bias pada *output gate*


h_t = hasil *output* pada *time step* t
 \tanh = fungsi tanh

2.7 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang digunakan pada *neural network* untuk mengaktifkan atau tidak mengaktifkan neuron. Fungsi ini dipakai untuk menentukan keluaran suatu neuron. Fungsi aktivasi bekerja seperti reseptor, menunggu rangsangan dan meresponnya dengan efek tertentu. Sehingga sebagai penyaring nilai yang masuk menjadi keluaran dengan rentang tertentu, rentang tersebut mengubah data yang non-linear menjadi linear sehingga proses lapisan berikutnya akan lebih mudah (Pasaribu, dkk., 2020).

Heaton (2008) mengatakan bahwa terdapat beberapa fungsi aktivasi yang dapat digunakan untuk *neural network*, yaitu:

1. Fungsi sigmoid



Gambar 2. Grafik Fungsi Sigmoid.

Fungsi aktivasi sigmoid biasanya digunakan pada model fungsi logistik atau nama lain dari fungsi ini yaitu fungsi sigmoid logistik (*logistic sigmoid function*). Input untuk fungsi sigmoid berupa bilangan real dan output fungsi ini memiliki range antara 0 sampai 1. Rumus fungsi sigmoid adalah sebagai berikut:


$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.29)$$

dengan :

x = data

e = bilangan euler

2. Fungsi tanh



Gambar 3. Grafik Fungsi Tanh.

Fungsi tanh atau lebih dikenal dengan *hyperbolic tangent* adalah fungsi aktivasi yang dikembangkan dari fungsi aktivasi sigmoid. Input untuk fungsi aktivasi tanh berupa bilangan real dan output dari fungsi tersebut memiliki range antara -1 sampai 1 yang mirip dengan fungsi sigmoid tetapi lebih luas jangkauannya. Rumus fungsi tanh adalah sebagai berikut:


$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.30)$$

dengan :

x = data

e = bilangan euler

3. Fungsi linear



Gambar 4. Grafik Fungsi Linear

Fungsi linear berbanding lurus ke input. Setiap input yang masuk, dikalikan dengan bobot untuk setiap neuron, dan menghasilkan sinyal yang sebanding dengan input. Untuk masalah peramalan, disarankan untuk menggunakan fungsi aktivasi linear (Zhang, dkk., 1998). Rumus fungsi linear adalah sebagai berikut:

$$f(x) = x \quad (2.31)$$

dengan :

x = data

2.8 *Scaling Data*

Scaling data atau normalisasi data merupakan teknik mengubah nilai numerik dalam dataset ke skala umum, tanpa mendistorsi perbedaan dalam rentang nilai (Ambarwari, dkk., 2020). Normalisasi ini berfungsi untuk memperkecil ukuran data tanpa mengubah data aktual. Normalisasi data akan membantu mempercepat proses pembelajaran pada *machine learning*. Terdapat dua teknik yang dapat digunakan untuk melakukan normalisasi data adalah sebagai berikut:

a. Normalisasi *Min-Max*

Aldi, dkk. (2018) menyatakan bahwa untuk meminimalkan error, dilakukan normalisasi pada dataset dengan mengubah data aktual menjadi nilai dengan range interval [0,1]. Rumus normalisasi *min-max* adalah sebagai berikut:

$$x' = \frac{(x - \min_x)}{(\max_x - \min_x)} \quad (2.32)$$

dengan :

x' = data hasil normalisasi

x = data asli

\min_x = nilai minimum dari data

\max_x = nilai maksimum dari data

b. *Standard Scaler*

Metode normalisasi ini didasarkan pada *mean* dan standar deviasi. Standarisasi suatu dataset melibatkan pengubahan skala distribusi nilai, sehingga nilai rata-rata (*mean*) yang diamati adalah 0 dan standar deviasi adalah 1 (Ambarwari, dkk., 2020). Rumus standard scaler adalah sebagai berikut:

$$x' = \frac{(x - x_{mean})}{x_{std}} \quad (2.33)$$

dengan :

x' = data hasil normalisasi

x = data asli

x_{mean} = rata-rata dari data

x_{std} = standar deviasi dari data

2.9 *Hyperparameter*

Hyperparameter adalah parameter yang ditetapkan sebelum model pembelajaran mesin mulai belajar. Hikmaturokhman, dkk. (2022) menyatakan bahwa beberapa parameter pada *deep learning* adalah sebagai berikut:

- a. Jumlah *hidden layer*.
- b. Jumlah *hidden neuron* pada setiap *hidden layer*.
- c. Ukuran *batch* (mewakili jumlah data *train* selama periode).
- d. Iterasi, misalnya terdapat 10.000 dataset dengan ukuran batch 200 maka satu periode terdiri dari 50 iterasi (10.000 dibagi 200).
- e. Periode (mewakili satu set iterasi).
- f. Tingkat pembelajaran.
- g. Parameter regulasi (keteraturan parameter).

Hyperparameter adalah variabel konfigurasi di luar model dan nilainya sulit diperkirakan dari data. Artinya, *hyperparameter* tidak dapat dipelajari langsung dari data dalam standar model *training*. Sebagai gantinya, *machine learning engineer* harus dapat menentukan *hyperparameter* sebelum *training* dan dilakukan *trial and error* untuk memperoleh nilai prediksi terbaik (Hikmaturokhman, dkk., 2022).

2.10 *Hybrid (VARX – LSTM)*

Metode *hybrid* adalah suatu metode yang mengkombinasikan satu atau lebih metode tunggal. Salah satu contohnya yaitu *hybrid VARX – LSTM*. Zhang (2003) menyatakan bahwa beberapa studi empiris telah menyatakan bahwa dengan menggabungkan beberapa model yang berbeda, akurasi peramalan dapat ditingkatkan dibandingkan model individualnya. Ide dasar dari kombinasi model dalam peramalan adalah menggunakan fitur unik masing-masing model untuk menangkap pola yang berbeda dalam data, misalnya pola linear dan non-linear.

Secara umum, kombinasi model deret waktu yang memiliki struktur autokorelasi linear dan non-linear dapat dituliskan sebagai berikut (Zhang, 2003):

$$y_t = L_t + N_t \quad (2.34)$$

dengan :

- y_t = data aktual ke t
- L_t = komponen linear ke t
- N_t = komponen nonlinear ke t
- t = indeks waktu

Zhang (2003) menyatakan bahwa dua komponen pada persamaan (2.34) digunakan untuk meramalkan data. Pertama, digunakan VARX untuk meramalkan data sebagai komponen linear. Kedua, residual dari model linear sebagai komponen nonlinear. Misalkan, e_t menunjukkan residual pada model linear saat t waktu, maka:

$$e_t = y_t - L'_t \quad (2.35)$$

dengan :

- y_t = data aktual ke t
- L'_t = nilai peramalan dari komponen linear ke t
- N_t = komponen nonlinear ke t
- t = indeks waktu

Dalam mendiagnosis model linear, residual sangat penting. Pemodelan residual menggunakan LSTM dapat menemukan hubungan nonlinear pada data deret waktu. Maka, pemodelan residual menggunakan LSTM dengan n input dapat dituliskan sebagai berikut:

$$e_t = f(e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n)} + \varepsilon_t) \quad (2.36)$$

dengan :

- e_t = data residual ke t
- f = fungsi nonlinear dari LSTM
- ε_t = *error*
- t = indeks waktu

Persamaan (2.36) dapat ditulis sebagai N'_t . Maka, peramalan *hybrid* merupakan kombinasi dari dua komponen yang dapat dituliskan sebagai berikut (Zhang, 2003):

$$y'_t = L'_t + N'_t \quad (2.37)$$

dengan :

- y'_t = nilai peramalan dari model *hybrid* ke t
- L'_t = nilai peramalan dari komponen linear ke t
- N'_t = nilai peramalan dari komponen nonlinear ke t
- t = indeks waktu

Pemodelan *hybrid* dapat diperoleh dengan dua tahapan. Pertama, model VARX digunakan untuk meramalkan komponen linear. Kedua, model LSTM digunakan untuk memodelkan residual dari model VARX. Hasil LSTM dapat digunakan untuk meramalkan residual pada model VARX.

2.11 Akurasi

Akurasi peramalan merupakan ukuran kesalahan peramalan tentang tingkat perbedaan antara nilai aktual dengan nilai peramalan. Terdapat beberapa metode yang dapat digunakan, diantaranya adalah *Mean Absolute Percentage Error* (MAPE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE).

1. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error (MAPE) adalah *absolute* rata-rata dari selisih nilai asli dan nilai prediksi sehingga nantinya dapat diketahui persentase kesalahan model yang dihasilkan (Ivan & Purnomo, 2022). Semakin kecil nilai MAPE, maka metode semakin baik digunakan untuk peramalan.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100\% \quad (2.38)$$

dengan :

- Y_t = data aktual ke t
 \hat{Y}_t = data peramalan ke t
 n = banyaknya periode peramalan
 t = indeks waktu

2. Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah rata-rata selisih nilai asli dan nilai prediksi yang dikuadratkan. Semakin kecil nilai MSE maka nilai prediksi semakin mendekati nilai sebenarnya (Baluk, dkk., 2020). Semakin kecil nilai MSE, maka metode yang digunakan semakin baik untuk peramalan.

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.39)$$

dengan :

- Y_t = data aktual ke t
 \hat{Y}_t = data peramalan ke t
 n = banyaknya periode peramalan
 t = indeks waktu

3. Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah akar kuadrat dari rata-rata selisih nilai asli dan nilai prediksi dimana hasil akhirnya menunjukkan seberapa jauh nilai asli dan prediksi model (Ivan & Purnomo, 2022). Hasil peramalan akan semakin baik bila nilai RMSE yang dihasilkan semakin kecil atau mendekati nol.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (2.40)$$

dengan :

- Y_t = data aktual ke t
 \hat{Y}_t = data peramalan ke t
 n = banyaknya periode peramalan
 t = indeks waktu

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 pada penelitian ini merupakan data sekunder yang diperoleh dari situs *website* Badan Pusat Statistik (BPS) dengan link <https://www.bps.go.id/indicator/13/383/1/suku-bunga-kredit-rupiah-menurut-kelompok-bank.html> untuk data suku bunga kredit investasi dan <https://www.bps.go.id/indicator/3/1/1/inflasi-umum-.html> untuk data inflasi. Adapun data yang diambil yaitu data suku bunga kredit investasi pada bank persero dan bank umum sebagai peubah endogen dan inflasi sebagai peubah eksogen.

Y_1 = suku bunga kredit investasi pada bank persero

Y_2 = suku bunga kredit investasi pada bank umum

X = inflasi

Bank persero merupakan bank yang seluruh modalnya berasal dari kekayaan negara yang dipisahkan dan pendiriannya di bawah UU tersendiri. Bank umum merupakan bank yang dalam kegiatannya menghimpun dana dari masyarakat, memberikan pinjaman kepada masyarakat, serta memberikan seluruh layanan

dalam lalu lintas pembayaran. Periode waktu data yang digunakan yaitu dari bulan Januari 2009 hingga Desember 2021. Data diambil setiap satu bulan sekali sehingga terdapat 156 data.

Tabel 2. Data Suku Bunga Kredit Investasi dan Data Inflasi


<i>Date</i>	Suku Bunga Bank Persero	Suku Bunga Bank Umum	Inflasi
2009-01-01	13,83	14,37	-0,07
2009-02-01	13,66	14,23	0,21
⋮	⋮	⋮	⋮
2021-11-01	8,54	8,44	0,37
2021-12-01	8,49	8,35	0,57

3.3. Metode Penelitian

Berikut merupakan tahapan dari pengerjaan metode *hybrid VARX – LSTM* :

1. Menginput data suku bunga kredit investasi pada bank persero sebagai endogen (Y_1), suku bunga kredit investasi pada bank umum sebagai endogen (Y_2), dan inflasi sebagai eksogen (X).
2. Menguji kestasioneran data menggunakan plot data dan uji *Augmented Dickey-Fuller* (ADF), jika belum stasioner maka dilakukan *differencing*.
3. Menentukan orde pada model VARX menggunakan *Akaike's Information Criteria* (AIC) untuk menghasilkan model terbaik.
4. Melakukan estimasi parameter dari model terbaik VARX.
5. Berdasarkan model VARX terbaik, kemudian model tersebut digunakan untuk memprediksi dan meramalkan suku bunga kredit investasi.
6. Menentukan data residual yang merupakan selisih antara data aktual dengan data prediksi dari suku bunga kredit investasi.
7. Melakukan uji *normalitas* multivariat pada *residual* dengan menggunakan *Jarque-Bera Test*.

8. Melakukan uji *residual white noise* dengan menggunakan uji statistik Ljung – Box.
9. Data prediksi dan data residual VARX digunakan sebagai input data pada metode LSTM.
10. Melakukan *splitting* data dengan skema 70% *training*, 30% *testing* dan 80% *training*, 20% *testing*. Pembagian data *splitting* dilakukan secara urut dimulai dari data pertama, kedua, dan seterusnya.
11. Membangun model LSTM berdasarkan data prediksi dan residual VARX.
12. Menentukan parameter model LSTM dengan menggunakan *hyperparameter tuning* untuk menentukan parameter terbaik.
13. Melakukan prediksi dan peramalan dengan model LSTM menggunakan data prediksi model VARX.
14. Melakukan prediksi dan peramalan dengan model LSTM menggunakan data residual model VARX.
15. Menggabungkan hasil prediksi dan peramalan dari kedua model LSTM dengan proses penjumlahan,
16. Hasil dari penggabungan data prediksi dan data residual merupakan model *hybrid* VARX – LSTM.



Gambar 5. *Workflow* VARX – LSTM

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Kesimpulan yang didapatkan selama proses pengerjaan penelitian peramalan suku bunga kredit investasi di Indonesia dengan metode *hybrid VARX – LSTM* adalah sebagai berikut:

1. Metode *hybrid VARX – LSTM* merupakan metode yang baik untuk melakukan prediksi dan peramalan untuk data deret waktu seperti data suku bunga kredit investasi bank persero dan bank umum. Nilai evaluasi yang diperoleh pada skema data 70% data *training* dan 30% data *testing* yaitu MSE sebesar 0,02496, RMSE sebesar 0,15799, dan MAPE sebesar 0,01292. Sedangkan untuk skema data 80% data *training* dan 20% data *testing* diperoleh nilai evaluasi MSE sebesar 0,02354, RMSE sebesar 0,15342 dan MAPE sebesar 0,01349.
2. Skema *splitting* data 80% data *training* dan 20% data *testing* memiliki nilai evaluasi yang lebih kecil dibandingkan dengan skema *splitting* data 70% data *training* dan 30% data *testing*.
3. Model *hybrid VARX – LSTM* dapat melakukan peramalan dengan baik dan hasil yang diperoleh mengikuti pola data *ter-update* dari suku bunga kredit bank persero dan bank umum dengan skema *splitting* data 80% data *training* dan 20% data *testing*.
4. Peramalan menggunakan model *hybrid VARX – LSTM* memiliki hasil yang lebih baik dibandingkan dengan peramalan menggunakan model VARX.

5.2 Saran

Saran yang diajukan oleh peneliti selanjutnya adalah menggunakan data yang lebih banyak untuk melakukan analisis. Data yang lebih banyak dapat digunakan untuk melakukan splitting data yang lebih bervariasi. Penambahan data juga dapat menghasilkan prediksi data yang lebih baik.

DAFTAR PUSTAKA

- Agustin, N., Ibtnas, R., & Nursalam. 2019. Implementasi Metode Vector Autoregressive (VAR) dalam Meramalkan Jumlah Penduduk. *Jurnal Matematika dan Statistika serta Aplikasinya*. 7(2): 55-60.
- Akbar, R., Santoso, R., & Warsito, B. 2022. Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short Term Memory (LSTM). *Jurnal Gaussian*. 11(4): 572-579.
- Aldi, M. W. P., Jondri, & Aditsania, A. 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *e-Proceeding of Engineering*. 5(2): 3548-3554.
- Ambarwari, A., Adrian, Q. J., & Herdiyeni, Y. 2020. Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning untuk Identifikasi Tanaman. *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)*. 4(1): 117-122.
- Baluk, A. P., Yasin, H., & Sugito. 2020. Peramalan Tinggi Gelombang Laut Dengan Metode Vector Autoregressive-Radial Basis Function Network (Var-Rbfn). *J Statistika*. 13(1): 39-46.
- Caliwag, A. C. & Lim, W. 2019. Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications. *IEEE Acces*. 7(10): 59680-59689.
- Chung, H. & Shin, K. 2018. Genetic Algorithm-Optimized Long Short-Term Memory Network for Stock Market Prediction. *Sustainability*. 10: 1-18.
- Darmawi, H. 2012. *Manajemen Perbankan*. Bumi Aksara, Jakarta.

- Dave, E., Leonardo, A., Jeanice, M., & Hanafiah, N. 2021. Forecasting Indonesia Export using a Hybrid Model ARIMA – LSTM. *Elsevier B.V.* **179**(8): 480-487.
- Fadli, F., Suwilo, S., & Zarlis, M. 2022. Model Prediksi Data Besar Distribusi Produk Farmasi: Analisis Kinerja Model Deep Learning. *CSRID Journal*. **14**(1): 68-80.
- Ferry, C. R., Irwan, & Nurfadilah. 2018. Peramalan Tingkat Suku Bunga Pasar Uang Antar Bank (PUAB) dengan Vector Autoregressive Exogenous (VARX). *Jurnal MSA*. **6**(1): 51-60.
- Gujarati, D. N. 2004. *Basic Econometrics*. 4th Edition. McGraw-Hill, Inc., Singapore.
- Halimatuzzahro, F. & Lestari, F. A. D. 2021. Peramalan Suku Bunga Kredit Rupiah Modal Kerja Pada Bank Swasta Nasional di Indonesia. *Jurnal Ilmiah Penalaran dan Penelitian Mahasiswa*. **5**(1): 14-33.
- Heaton, J. 2008. *Introduction to Neural Networks with Java*. Heaton Research, Inc., St. Louis.
- Hikmaturokhman, A., Nafi'ah, H., Larasati, S., Wahyudin, A., Ariprawira, G., & Pramono, S. 2022. Deep Learning Algorithm Models for Spam Identification on Cellular Short Message Service. *Journal of Communications*. **17**(9): 769-776.
- Hogg, R. V., Tanis, E. A., & Zimmerman, D. L. 2015. *Probability and Statistical Inference*. 9th Edition. Pearson Education, USA.
- Ivan, E. & Purnomo, H. D. 2022. Forecasting Prices of Fertilizer Raw Materials Using Long Short Term Memory. *Jurnal Teknik Informatika*. **3**(6): 1663-1673.
- Jabnabillah, F. & Margina, N. 2022. Analisis Korelasi Pearson dalam Menentukan Hubungan Antara Motivasi Belajar dengan Kemandirian Belajar pada Pembelajaran Daring. *Jurnal Sintak*. **1**(1): 14-18.

- James, G., Witten, D., Hastie, T., & Tibshirani, R. 2013. *An Introduction to Statistical Learning – with Applications in R*. Springer Science and Business Media, New York.
- Julian, R. & Pribadi, M. R. 2021. Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *Jurnal Teknik Informatika dan Sistem Informasi*. **8**(3): 1596-1606.
- Kezia, C., Amril, & Amzar, Y. V. 2020. Analisis perbedaan pengaruh kebijakan suku bunga bank sentral terhadap inflasi di Indonesia. *E-Journal Perdagangan Industri dan Moneter*. **8**(2): 99-112.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. 2nd Edition. John Wiley & Sons Inc., USA.
- 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.
- Prahitama, A., Rusgiyono, A., & Utami, T. W. 2019. Pemodelan Vector Autoregressive Exogenous (VARX) Pada Nilai Inflasi Terhadap PDRB di Jawa Tengah. *Jurnal Statistika*. **7**(2): 133-136.
- Rambha, U. B. & Seshashayee, M. 2022. Time Series Augmentation based on Vector Auto Regression and Long Short Term Memory method for Air Quality Prediction. *International Journal of Mechanical Engineering*. **7**(4): 502-512.
- Rosyidah, H., Rahmawati, R., & Prahitama, A. 2017. Pemodelan Vector Autoregressive X (VARX) Untuk Meramalkan Jumlah Uang Yang Beredar di Indonesia. *Jurnal Gaussian*. **6**(3): 333-343.
- Salsabila, N. A., Wahyuningsih, S., & Purnamasari, I. 2022. Pemodelan Vector Autoregressive Exogenous (VARX) Untuk Meramalkan Data Ekspor dan Impor Total di Indonesia. *Jambura Journal of Probability and Statistics*. **3**(2): 128-140.

- Supriadi, G. 2021. *Statistik Penelitian Pendidikan*. UNY Press, Yogyakarta.
- Tian, C., Ma, J., Zhang, C., & Zhan, P. 2018. A Deep Neural Network for Short-Term Load Forecast Based on Long Short Term Memory Network and Convolutional Neural Network. *Energies*. **11**: 1-13.
- Ulumuddin, I., Sunardi, & Fadlil, A. 2020. Bitcoin Price Prediction Using Long Short Term Memory (LSTM). *Jurnal Mantik*. **4**(2): 1090-1095.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd Edition. Pearson Education Hall, New Jersey.
- Warsono, Russel, E., Wamiliana, Widiarti, & Usman, M. 2019. Vector Autoregressive with Exogenous Variable Model and its Application in Modeling and Forecasting Energy Data: Case Study of PTBA and HRUM Energy. *International Journal of Energy Economics and Policy*. **9**(2): 390-398.
- Yin, C., Zhu, Y., Fei, J., & He, X. 2017. A Deep Learning Approach for Intrusion Detection Using Recurrent Neural Networks. *IEEE Acces*. **5**: 21954-21961.
- Yu, Y., Si, X., Hu, C., & Zhang, J. 2019. A Review of Recurrent Neural Networks: LSTM Cell and Network Architectures. *Neural Computation*. **31**(7): 1235-1270.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. 1998. Forecasting with Artificial Neural Networks: The State of The Art. *International Journal of Forecasting*. **14**: 35-62.
- Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50**: 159-175.