

**PERBANDINGAN METODE *LONG-SHORT TERM MEMORY* DAN
GATED RECURRENT UNIT UNTUK MEMPREDIKSI NILAI EKSPOR
MIGAS-NONMIGAS DI INDONESIA**

(Skripsi)

Oleh

**MAYDIA EGI NURAINI
1817031027**



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

ABSTRACT

COMPARISON OF LONG-SHORT TERM MEMORY AND GATED RECURRENT UNIT METHODS FOR PREDICTING THE VALUE OF OIL AND GAS AND NON-OIL AND GAS EXPORTS IN INDONESIA

By

MAYDIA EGI NURAINI

The development of export value affects economic growth in Indonesia. This activity provides an important role and great benefits for both oil and gas and non-oil and gas components, however the movement of export values from time to time seems to fluctuate even though it is not too big, so that it will be predict if there are any opportunity to increase the value of exports in Indonesia. In this study, oil and gas and non-oil and gas export values will be forecasted using two methods to obtain the best method that has a minimum error value, namely LSTM (Long-Short Term Memory) and GRU (Gated Recurrent Unit) for year 2022 to 2023. The evaluation model used is Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The RMSE and MAPE values for the LSTM method obtained were 0.0668 and 0.9998% for the oil and gas component and 0.0717 and 0.9999% for the non-oil and gas component. Meanwhile, the RMSE and MAPE values for the GRU method were 0.0655 and 0.9998% for the oil and gas component and 0.0697 and 0.9999% for the non-oil and gas component.

Keywords: Exports, Forecasting, LSTM, GRU, RMSE, MAPE

ABSTRAK

PERBANDINGAN METODE *LONG-SHORT TERM MEMORY* DAN *GATED RECURRENT UNIT* UNTUK MEMPREDIKSI NILAI EKSPOR MIGAS-NONMIGAS DI INDONESIA

Oleh

MAYDIA EGI NURAINI

Perkembangan nilai ekspor berpengaruh terhadap pertumbuhan ekonomi di Indonesia. Kegiatan ini memberikan peranan penting dan manfaat yang besar, baik komponen migas dan nonmigas, tetapi pergerakan nilai ekspor dari waktu ke waktu terlihat berfluktuasi walaupun tidak terlalu besar, sehingga akan dilihat adakah peluang untuk meningkatkan nilai ekspor di Indonesia. Dalam penelitian ini akan dilakukan peramalan nilai ekspor migas-nonmigas menggunakan dua metode untuk mendapatkan metode terbaik yang memiliki nilai *error* yang minimum, yaitu LSTM (*Long-Short Term Memory*) dan GRU (*Gated Recurrent Unit*), hasil yang diperoleh digunakan untuk menentukan peramalan pada tahun 2022 sampai 2023. Evaluasi model yang digunakan adalah *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Nilai RMSE dan MAPE untuk metode LSTM yang diperoleh sebesar 0,0668 dan 0,9998% untuk komponen migas dan 0,0717 dan 0,9999% untuk komponen nonmigas. Sedangkan nilai RMSE dan MAPE untuk metode GRU sebesar 0,0655 dan 0,9998 % untuk komponen migas dan 0,0697 dan 0,9999% untuk komponen nonmigas

Kata Kunci: Ekspor, Peramalan, LSTM, GRU, RMSE, MAPE

**PERBANDINGAN METODE *LONG-SHORT TERM MEMORY* DAN
GATED RECURRENT UNIT UNTUK MEMPREDIKSI NILAI EKSPOR
MIGAS-NONMIGAS DI INDONESIA**

Oleh

MAYDIA EGI NURAINI

Skripsi

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

Pada

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



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

Judul Skripsi : **PERBANDINGAN METODE *LONG -SHORT TERM MEMORY* DAN *GATED RECURRENT UNIT* UNTUK MEMPREDIKSI NILAI EKSPOR MIGASNONMIGAS DI INDONESIA**

Nama Mahasiswa : **Maydia Egi Nuraini**

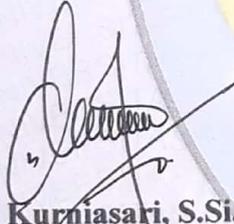
Nomor Pokok Mahasiswa : **1817031027**

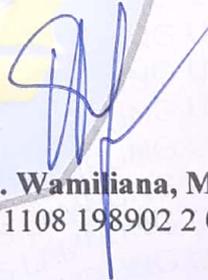
Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

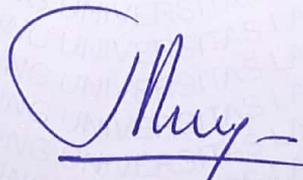


1. Komisi Pembimbing


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


Prof. Dra. Wamiliana, M.A., Ph. D.
NIP. 19631108 198902 2 001

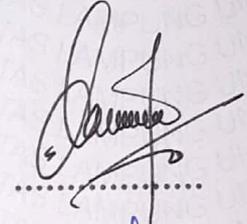
2. Ketua Jurusan Matematika


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

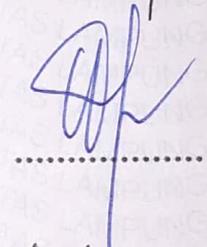
MENGESAHKAN

1. Tim Penguji

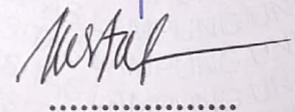
Ketua : **Dian Kurniasari, S.Si., M.Sc.**



Sekretaris : **Prof. Dra. Wamiliana, M.A., Ph. D.**



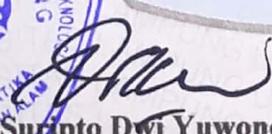
Penguji
Bukan Pembimbing : **Prof. Drs. Mustofa Usman, M.A., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Supto Dwi Yuwono, S.Si., M.T.
NIP. 19740705 200003 1 001



Tanggal Lulus Ujian Skripsi : **23 Juni 2022**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini :

Nama Mahasiswa : Maydia Egi Nuraini

Nomor Pokok Mahasiswa : 1817031027

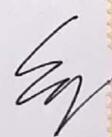
Jurusan : Matematika

Judul Skripsi : **PERBANDINGAN METODE *LONG - SHORT TERM MEMORY* DAN *GATED RECURRENT UNIT* UNTUK MEMPREDIKSI NILAI EKSPOR MIGAS-NONMIGAS DI INDONESIA**

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

Bandar Lampung, 23 Juni 2022

Penulis,



Maydia Egi Nuraini

RIWAYAT HIDUP

Penulis bernama Maydia Egi Nuraini lahir di Srisawahan pada 20 September 2000. Penulis merupakan anak pertama dari dua bersaudara dari pasangan Bapak Muhammad Sodik dan Ibu Ratiana Firdianti.

Penulis mengawali pendidikan di Taman Kanak-Kanak (TK) Pertiwi pada tahun 2005-2006. Kemudian menempuh pendidikan Sekolah dasar (SD) di SDN 1 Srisawahan pada tahun 2006 – 2012. Kemudian melanjutkan ke Sekolah Menengah Pertama di SMPN 4 Metro pada tahun 2012-2015, Sekolah Menengah Atas di SMAN 1 Metro pada tahun 2015-2018. Pada tahun 2018 penulis terdaftar sebagai mahasiswa Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SNMPTN.

Selama menjadi mahasiswa penulis aktif dalam mengikuti kegiatan organisasi Himpunan Mahasiswa Matematika (HIMATIKA) FMIPA UNILA periode 2019. Pada Tahun 2020 penulis melakukan Kuliah Kerja Praktik (KP) di Badan Pusat Statistik Kota Metro serta mengikuti kegiatan Kerja Kuliah Nyata di Desa Srisawahan, Lampung Tengah. Selama menjadi mahasiswa penulis juga mengikuti program MBKM, yaitu KMMI pada bidang *Data Science Fundamental* dan mengikuti *Microcredential AI*.

KATA INSPIRASI

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

(Q.S Ar-Rum : 60)

“Dan hanya kepada Tuhanmulah hendaknya kamu berharap.”

(Q.S Al-Insyirah : 8)

Sungguh atas kehendak Allah semua ini terwujud, tiada kekuatan kecuali dengan pertolongan Allah.

(Q.S Al-Kahfi : 39)

Seseorang yang bersabar tidak akan pernah kehilangan kesuksesan meskipun membutuhkan waktu yang lama untuk mencapainya.

(Ali Bin Abi Thalib)

Bukan tentang siapa yang berlari paling cepat, tapi tentang siapa yang bisa memaknai proses dari setiap perjalanan.

(Maydia Egi Nuraini)

PERSEMBAHAN

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

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

Bapak Muhammad Sodik dan Ibu Ratiana Firdianti

Terima kasih kepada kedua orang tuaku atas segala pengorbanan, motivasi, doa dan ridho kalian serta dukungannya selama ini. Terimakasih telah memberikan pelajaran berharga kepada anakmu ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi semua orang.

Dosen Pembimbing dan Pembahas

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

Sahabat-sahabatku

Terimakasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasinya, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun

Almamater Tercinta Universitas Lampung

SANWACANA

Segala puji dan syukur penulis ucapkan kepada Allah SWT atas segala nikmat dan karunia-Nya yang tak terhingga sehingga penulis dapat menyelesaikan skripsi yang berjudul “Perbandingan Metode *Long-Short Term Memory* dan *Gated Recurrent Unit* untuk Memprediksi Nilai Ekspor Migas-Nonmigas Di Indonesia”. Penulisan skripsi ini tidak dapat diselesaikan tanpa adanya bimbingan, bantuan, dan dukungan dari berbagai pihak sehingga pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Ibu Dian Kurniasari, S.Si., M.Sc., selaku dosen pembimbing I yang senantiasa membimbing, memberi masukan serta saran serta mendukung penulis dalam menyelesaikan skripsi ini.
2. Ibu Prof. Dra. Wamiliana, M.A., Ph.D. selaku dosen pembimbing II yang telah memberikan bimbingan, pengarahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
3. Bapak Prof. Drs. Mustofa M.A., Ph.D. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga skripsi ini dapat diselesaikan.
4. Bapak Prof.Drs. Mustofa M.A., Ph.D., selaku dosen pembimbing akademik yang telah memberikan bimbingan dan arahan selama masa perkuliahan.
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. Suropto Dwi Yuwono, S.Si., M.T. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Kedua Orang Tuaku, Bapak Muhammad Sodik dan Ibu Ratiana Firdianti yang selalu memberikan motivasi serta dukungannya.
8. Seluruh dosen, staf, karyawan Jurusan Matematika Fakultas Matematika dan

Ilmu Pengetahuan Alam Universitas Lampung.

9. Keluarga sekalian yang selalu memberikan semangat kepada penulis serta doa-doanya.
10. Teman-teman kosanku Intan, Mazi, Mufliha, Risha, Silvi, dan Virda yang selalu memberikan bantuan, memberikan cerita serta memberikan semangat dalam hal apapun.
11. Anggel, Caca, Nuva, Riska, Shabe, Sofa, Zamhara, yang telah membantu banyak selama diperkuliahkan dan selalu memberikan semangat.
12. Orang-orang baik yang namanya tidak bisa saya sebutkan satu persatu yang telah menjadi teman terbaik penulis yang selalu memberikan semangat dan menemani penulis dalam keadaan apapun serta telah memberikan pengalaman dan banyak cerita selama masa perkuliahan.
13. Teman-teman seperbimbingan yang selalu memberikan dukungan dan motivasi serta doa-doanya (Alifia, Dalfa, Farel, Febi, Ferzy, Joshua, Luthfia, Oktin, Putri, Rekti, Shavira, Sulis, Virda, Zaenal).
14. Semua teman-teman sejurusan matematika 2018 dan teman kelas A yang telah membantu serta memberikan semangat kepada penulis.
15. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

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

Bandar Lampung, 23 Juni 2022

Penulis,

Maydia Egi Nuraini

DAFTAR ISI

	Halaman
DAFTAR TABEL	xv
DAFTAR GAMBAR	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian	4
1.3 Manfaat Penelitian	4
II. TINJAUAN PUSTAKA	5
2.1 Peramalan (<i>Forecasting</i>)	5
2.2 Deret Waktu (<i>Time Series</i>)	6
2.3 Data Mining	7
2.4 <i>Machine Learning</i>	8
2.5 <i>Deep Learning</i>	9
2.6 <i>Recurrent Neural Network</i>	10
2.7 Fungsi Aktivasi.....	11
2.8 <i>Long-Short Term Memory</i>	12
2.9 <i>Gated Recurrent Unit</i>	17
2.10 Denormalisasi Data.....	19
2.11 Evaluasi Model.....	19
2.12 Inisialisasi Parameter	21
III. METODE PENELITIAN	22
3.1 Waktu dan Tempat Penelitian	22
3.2 Data Penelitian.....	22
3.3 Metode Penelitian	22
IV. HASIL DAN PEMBAHASAN	25
4.1 Proses Data Mining.....	25
4.1.1 Seleksi Data	25
4.1.2 <i>Data Preprocessing</i>	26
4.2 Pembagian Data <i>Training</i> dan Data <i>Testing</i>	28
4.3 Inisialisasi Parameter Model	29

4.4	Membangun Model <i>Long-Short Term Memory</i> dan <i>Gated Recurrent Unit</i>	29
4.4.1	Model <i>Long-Short Term Memory</i> (LSTM).....	30
4.4.2	Model <i>Gated Recurrent Unit</i> (GRU).....	31
4.5	Pengujian Model.....	33
4.6	Denormalisasi Data.....	35
4.7	Hasil Prediksi Model LSTM dan GRU.....	35
4.8	Evaluasi Model LSTM dan GRU	40
4.9	Peramalan	41
V.	KESIMPULAN	45
	DAFTAR PUSTAKA	46
	LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
1. Data Awal Komponen Migas dan Nonmigas	25
2. Statistika Deskriptif.....	26
3. Hasil Normalisasi Data.....	27
4. Pembagian Data	28
5. <i>Hypertuning Parameter LSTM</i>	30
6. Parameter Optimal Model <i>Long-Short Term Memory</i>	30
7. <i>Hypertuning Parameter GRU</i>	32
8. Parameter Optimal Model <i>Gated Recurrent Unit</i>	32
9. Perbandingan Hasil Prediksi dan Data Aktual Model LSTM dan GRU Tahun 2014 Komponen Migas	38
10. Perbandingan Hasil Prediksi dan Data Aktual Model LSTM dan GRU Tahun 2014 Komponen Nonmigas	39
11. Evaluasi Model	40
12. Hasil Peramalan	42

DAFTAR GAMBAR

Gambar	Halaman
1. Pola Data <i>Time Series</i>	6
2. Arsitektur <i>Recurrent Neural Network</i>	10
3. Fungsi Aktivasi Sigmoid	11
4. Fungsi Aktivasi <i>Tangen Hiperbolik</i>	11
5. Arsitektur <i>Long-Short Term Memory</i>	12
6. Sel Memori <i>Long-Short Term Memory</i>	13
7. Alur <i>Forgot Gate</i>	13
8. Alur <i>Input Gate</i>	14
9. Alur <i>Cell State</i> Baru	16
10. Alur <i>Output Gate</i>	16
11. Arsitektur <i>Gated Recurrent Unit</i>	17
12. <i>Flowchart</i> Metode LSTM dan GRU	24
13. Plot Nilai Ekspor Migas dan Nonmigas	27
14. Grafik <i>Loss</i> Untuk LSTM Komponen Migas	33
15. Grafik <i>Loss</i> Untuk LSTM Komponen Nonmigas.....	34
16. Grafik <i>Loss</i> Untuk GRU Komponen Migas	34
17. Grafik <i>Loss</i> Untuk LSTM Komponen Nonmigas.....	35
18. Plot Hasil Prediksi dan Data Aktual Komponen Migas.....	36
19. Plot Hasil Prediksi dan Data Aktual Komponen Nonmigas.....	36
20. Plot Hasil Prediksi dan Data Aktual Komponen Migas.....	37
21. Plot Hasil Prediksi dan Data Aktual Komponen Nonmigas.....	37
22. Plot LSTM Hasil Peramalan Nilai Ekspor Migas.....	43
23. Plot LSTM Hasil Peramalan Nilai Ekspor Nonmigas	43
24. Plot GRU Hasil Peramalan Nilai Ekspor Migas	44
25. Plot GRU Hasil Peramalan Nilai Ekspor Nonmigas.....	44

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Perkembangan ilmu pengetahuan dan teknologi saat ini tidak lepas dari kekuatan ilmu matematika pada struktur dan penalaran yang digunakan sebagai landasan ilmu yang memiliki banyak manfaat dalam kehidupan sehari-hari, salah satunya adalah penerapan ilmu matematika yang digunakan sebagai suatu prediksi. Prediksi merupakan metode yang digunakan untuk memprediksi ketidakpastian di masa depan dalam upaya pengambilan keputusan yang lebih baik (Fauziah, dkk., 2016).

Sektor perekonomian di Indonesia salah satunya adalah kegiatan ekspor sangat berpengaruh terhadap keseimbangan kehidupan masyarakat pada saat ini. Ekspor memberikan peranan yang sangat penting bagi perekonomian suatu negara sehingga dapat memberikan manfaat yang besar bagi Indonesia sebagai penghasil devisa untuk meningkatkan pendapatan negara. Kegiatan ekspor dapat membantu perkembangan kegiatan industri di Indonesia, tetapi kegiatan ekspor di Indonesia masih mengalami permasalahan, salah satunya adalah tidak stabilnya kegiatan ekspor sehingga berdampak menurunkan nilai devisa yang didapat oleh Indonesia. Komponen ekspor yang berpengaruh terhadap pertumbuhan ekonomi di Indonesia terdiri dari kategori minyak bumi dan gas (migas) dan nonmigas. Berdasarkan data dari Badan Pusat Statistik yang divisualisasikan dalam bentuk grafik, pergerakan nilai ekspor di Indonesia baik komponen migas maupun nonmigas dari waktu ke waktu terlihat berfluktuasi walaupun tidak terlalu besar, sehingga untuk melihat adakah peluang untuk meningkatkan nilai ekspor migas-nonmigas di

Indonesia dengan melakukan suatu prediksi. Prediksi dapat membantu pihak pemerintah dalam menentukan kebijakan selanjutnya, sehingga langkah-langkah yang efektif untuk mengembangkan sektor perekonomian di Indonesia terutama pada komoditas ekspor dapat diterapkan menggunakan metode yang tepat. Metode prediksi data *time series* yang sering digunakan adalah ARIMA (*Autoregressive Integrated Moving Average*), tetapi metode ini memerlukan asumsi-asumsi yang harus dipenuhi dan hanya bisa memodelkan data yang bersifat stasioner atau linear, sehingga akan ditelusuri metode lain yang dapat digunakan untuk prediksi data *time series*.

Metode *time series* atau deret waktu merupakan metode yang sering digunakan dalam melakukan prediksi. Salah satu perkembangan metode *time series* adalah *deep learning*, metode ini memungkinkan untuk melakukan pembelajaran dengan lapisan yang lebih kompleks agar mendapatkan akurasi yang tinggi dan lebih efisien serta memberikan peramalan yang lebih akurat dibandingkan dengan metode peramalan tradisional karena mampu memodelkan data yang linear maupun nonlinear (Zhang, 2004). Salah satu metode *deep learning* adalah *Recurrent Neural Network* (RNN). RNN adalah jenis arsitektur jaringan saraf tiruan dimana kerjanya menggunakan *input* yang diproses secara berulang-ulang, tetapi metode ini tidak mampu menampung memori jangka panjang sehingga sulit untuk mengingat informasi sebelumnya, akibatnya informasi penting dari awal akan tertinggal. RNN merupakan pembelajaran jangka panjang dengan nilai gradien yang menghasilkan masalah menghilang (*vanishing*) atau meledaknya (*exploding*) gradien (Wiranda dan Sadikin, 2019).

Sehingga, untuk mengatasi masalah ini disusunlah arsitektur yang memanfaatkan sistem gerbang untuk menyimpan informasi jangka panjang. Sistem gerbang yang telah menunjukkan keunggulannya di berbagai riset adalah *Long-Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang merupakan salah satu varian dari RNN. Kedua metode ini dapat digunakan untuk pola data *time series* atau *sequential*. LSTM merupakan algoritma berbasis deret waktu yang dikenal lebih unggul dan andal dalam melakukan suatu prediksi sehingga dapat

menyimpan informasi dalam waktu yang lama dengan menggunakan tiga jenis *gate*, yaitu *input gate*, *forgot gate*, dan *output gate* dan mampu menangani kendala *vanishing gradient* pada RNN, sedangkan arsitektur GRU memiliki parameter yang lebih sedikit dan arsitekturnya lebih sederhana dari LSTM, sehingga cocok untuk data yang sedikit agar tidak terjadi *overfitting* dan tersusun atas dua *gate*, yaitu *reset gate* dan *update gate*. Arsitektur LSTM memiliki kompleksitas yang cukup tinggi karena memiliki 3 *sigmoid* dan 2 *tanh* dibandingkan dengan GRU yang memiliki 2 *sigmoid* dan *tanh* sehingga GRU memberikan konvergensi yang lebih cepat dan hasilnya dapat dibandingkan dengan LSTM (Hastomo, dkk., 2021).

Berdasarkan beberapa penelitian terkait penerapan algoritma *deep learning* telah banyak digunakan sebelumnya. Penelitian Aldi, dkk. (2018), dianalisis dengan pola *time series*, jumlah *neuron hidden*, *max epoch*, dan komposisi data latih dan uji terhadap akurasi prediksi, model yang dibangun menunjukkan prediksi harga bitcoin dengan baik. Saputra, dkk. (2020), melakukan prediksi data *sequential* dengan evaluasi model menggunakan nilai RMSE terkecil dari beberapa percobaan dan menunjukkan model yang cukup baik, tetapi beberapa hasil prediksi masih belum maksimal mendekati nilai aktual. Arunkumar, dkk. (2020), untuk evaluasi model menggunakan *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) terkecil diyakini sebagai model terbaik untuk peramalan.

Oleh karena itu, penelitian ini menerapkan metode RNN, yaitu LSTM dan GRU menggunakan data ekspor migas-nonmigas di Indonesia sehingga hasil yang diperoleh adalah metode terbaik dengan tingkat kesalahan yang kecil dilihat dari *Root Mean Square Error* (RMSE) dan *Mean Absolute Percent Error* (MAPE) serta dilakukan peramalan untuk dua tahun berikutnya.

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Untuk melakukan prediksi mengenai nilai ekspor migas dan nonmigas menggunakan metode LSTM dan GRU.
2. Untuk mengetahui hasil perbandingan kedua metode dilihat dari pengukuran akurasi model.
3. Untuk meramalkan nilai ekspor migas dan nonmigas di Indonesia pada tahun 2022-2023.

1.3 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Dapat memberikan pengetahuan terkait metode LSTM dan GRU.
2. Dapat mengetahui metode terbaik yang digunakan dalam suatu prediksi sehingga dapat dijadikan referensi untuk penelitian selanjutnya.
3. Sebagai bahan pertimbangan bagi pihak pemerintah dalam menentukan kebijakan selanjutnya terkait pengembangan sektor ekonomi pada ekspor migas-nonmigas.

II. TINJAUAN PUSTAKA

2.1 Peramalan (*Forecasting*)

Peramalan merupakan suatu proses dalam memperkirakan sesuatu yang mungkin terjadi di masa depan berdasarkan informasi pada masa lalu dan masa sekarang. Metode peramalan dikategorikan menjadi dua kategori, yaitu metode peramalan kualitatif dan metode kuantitatif. Menurut Makridakis, dkk. (1999), metode peramalan kualitatif didasarkan pada data kualitatif masa lalu berdasarkan pengetahuan dan pengalaman dari penulis, sedangkan metode peramalan kuantitatif didasarkan pada data kuantitatif pada informasi masa lalu dalam bentuk data yang numerik seperti model deret berkala (*time series*) dan model kausal.

Heizer dan Render (1996) menyatakan bahwa, jangka waktu peramalan terbagi menjadi tiga kategori, yaitu:

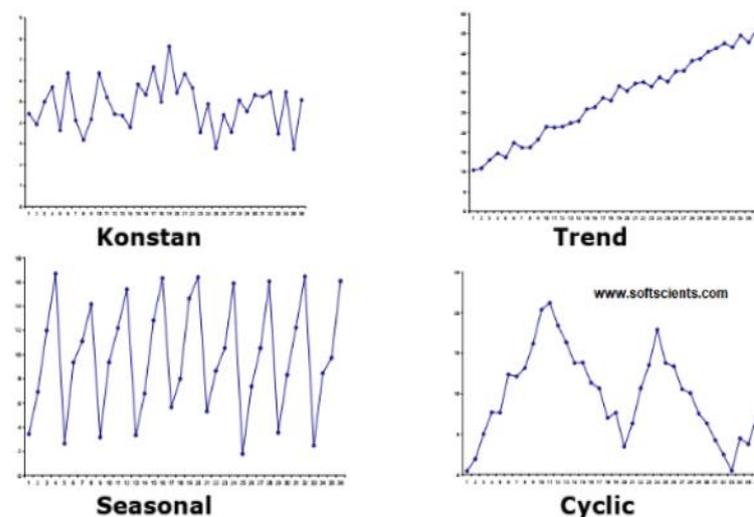
1. Peramalan jangka pendek, yaitu peramalan untuk jangka waktu kurang dari tiga bulan.
2. Peramalan jangka menengah, yaitu peramalan untuk jangka waktu antara tiga bulan sampai tiga tahun.
3. Peramalan jangka panjang, yaitu peramalan untuk jangka waktu lebih dari tiga tahun.

2.2 Deret Waktu (*Time Series*)

Time series merupakan serangkaian observasi terhadap suatu variabel yang diambil secara berurutan berdasarkan interval waktu yang tetap (Wei, 2006). Data *time series* adalah data yang terdiri dari satu objek namun meliputi beberapa periode waktu, yaitu harian, mingguan, bulanan, tahunan, dan lain-lain.

Menurut Hanke dan Wichern (2005), terdapat empat jenis pola data, yaitu:

1. Pola data horizontal terjadi jika data berfluktuasi pada suatu nilai konstan atau disekitar rata-rata data. Tipe data berkala ini disebut dengan data stasioner.
2. Pola data musiman merupakan variasi musiman yang merupakan gerakan yang berulang-ulang secara teratur selama kurang lebih satu tahun. Pola data musiman terjadi jika data tersebut dipengaruhi oleh faktor musiman misalnya kuartalan, bulanan, atau mingguan.
3. Pola data siklis merupakan pola data dengan gerakan naik atau turun secara siklis disekitar tren atau kondisi normal.
4. Pola data *trend* terjadi jika data tersebut bergerak pada jangka waktu tertentu dan cenderung menuju ke satu arah. Arah tersebut berupa kecenderungan naik atau turun.



Gambar 1. Pola Data *Time Series*

2.3 Data Mining

Data mining merupakan istilah yang diterapkan untuk menguraikan penemuan pengetahuan di dalam *database*. Berdasarkan Kusriani dan Emha (2009), data mining merupakan proses yang menggunakan teknik statistik, matematika, kecerdasan buatan, dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait dengan *database* yang besar. Dalam data mining untuk pengaplikasiannya merupakan bagian dari proses *Knowledge Discovery in Database* (KDD).

Berdasarkan Fayyad (1996) menyatakan bahwa, tahapan KDD adalah data mining dengan tahapan sebagai berikut.

1. Seleksi Data

Seleksi data merupakan proses pengambilan data yang berhubungan dengan analisis dari basis data dan dilakukan teknik perolehan sebuah pengurangan representasi dari data untuk meminimalkan hilangnya informasi data. Pemilihan atau seleksi data dari sekumpulan data operasional dilakukan sebelum tahap penggalian informasi dalam KDD dimulai. Data dari hasil seleksi digunakan untuk proses data mining.

2. *Pre-processing* Data

Sebelum proses data mining dilakukan perlu dilakukan proses *pre-processing* data mencakup membuang duplikasi data, memeriksa data yang hilang, memeriksa data yang tidak konsisten, dan memperbaiki kesalahan pada data.

3. Transformasi Data

Transformasi merupakan proses dalam pemilihan data yang telah dipilih, sehingga data tersebut sesuai dengan proses data mining. Dalam proses transformasi terdapat beberapa teknik, salah satunya adalah normalisasi data. Normalisasi merupakan teknik pada pemrosesan data untuk memperkecil rentang nilai pada suatu fitur atau keluaran untuk menghindari terjadinya beberapa anomali data dan tidak konsistensinya suatu data.

Lewis (2017), terdapat beberapa teknik normalisasi data salah satunya, yaitu:

a. *Min-max Normalization*

Teknik ini digunakan dalam mengatasi perbedaan nilai yang cukup besar antar dataset dengan mengubah nilai data aktual menjadi nilai dengan skala (0,1) tanpa mengubah informasi yang ada.

$$x' = \frac{(x-x_{min})}{(x_{max}-x_{min})} \quad (2.1)$$

dengan:

x' : data hasil normalisasi

x : data asli

X_{min} : nilai minimum dari x

X_{max} : nilai maksimum dari x

4. *Data mining*

Data Mining merupakan proses dalam mencari pola yang sesuai dari data yang ingin ditampilkan dengan menggunakan teknik maupun metode tertentu. Teknik maupun metode pada data mining sangat beragam.

5. Interpretasi atau Evaluasi

Pola informasi yang dihasilkan dari proses data mining perlu ditampilkan dalam bentuk yang mudah dimengerti oleh pihak yang berkepentingan.

2.4 *Machine Learning*

Machine learning merupakan pembelajaran mesin yang termasuk kedalam pendekatan *artificial intelligence* (Russell dan Norvig, 2016). *Machine learning* menggunakan teori statistik yang dapat memproses algoritma pembelajaran dengan jumlah informasi yang banyak dan menggunakan teori statistika dalam membangun model matematis untuk membuat kesimpulan dari sampel *input* yang tersedia. Ciri dalam *machine learning* adalah proses pelatihan (*test*) dan pembelajaran (*training*). Proses *training* ini akan membentuk *training set* yang

merupakan bagian dataset yang kita latih untuk menjalankan fungsi dari algoritma dan proses *test set ini* digunakan untuk melihat keakuratan atau performanya.

Dalam pembelajarannya *machine learning* dikelompokkan menjadi 2 yaitu :

1. Pembelajaran terarah (*supervised learning*) adalah proses pembelajaran terawasi dimana jika *output* yang diinginkan telah diketahui sebelumnya. Biasanya pembelajaran ini menggunakan data yang telah ada. Keterbatasan *supervised learning* adalah membutuhkan data dalam jumlah yang besar sehingga memakan waktu yang lama karena harus dilabel manual oleh manusia, serta membutuhkan validasi berulang dengan dataset lainnya untuk melatih ketepatan model. Salah satu algoritma yang termasuk adalah *neural network*.
2. Pembelajaran tidak terarah (*unsupervised learning*) adalah proses pembelajaran yang tidak terawasi dimana tidak memerlukan target *output*. Pada metode ini tidak dapat ditentukan hasil yang diharapkan selama proses pembelajaran. Tujuan metode ini adalah mengelompokkan unit yang memiliki kemiripan pada area tertentu. Keuntungannya adalah dapat menentukan pola tersembunyi dari data-data yang akan diidentifikasi, namun kekurangannya adalah sulitnya menentukan pola awal untuk membentuk algoritma.

2.5 *Deep Learning*

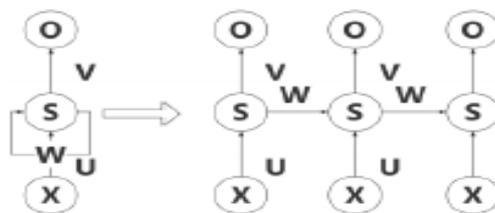
Deep learning merupakan cabang dari *machine learning* dimana menggunakan jaringan saraf tiruan yang terinspirasi dari fungsi otak manusia. *Deep learning* bertujuan agar membuat *machine learning* bekerja seperti otak manusia saat mempelajari sesuatu. *Deep learning* memiliki beberapa algoritma, yaitu *Convolution Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Untuk mengolah data *time series* metode yang digunakan adalah *Recurrent Neural Network* (RNN).

2.6 Recurrent Neural Network (RNN)

RNN merupakan jaringan saraf berulang yang merupakan salah satu jenis dari *Artificial Neural Network* yang telah disusun khusus agar dapat memproses data sekuensial sehingga dapat digunakan untuk mengolah data *time series*. RNN dikatakan jaringan saraf berulang karena *output* dari *hidden layer* yang sebelumnya akan digunakan kembali sebagai data *input* bagi pemrosesan selanjutnya. Berdasarkan teori, arsitektur RNN tidak dapat menangani ketergantungan jangka panjang dikarenakan tidak menyimpan informasi sebelumnya dengan baik yang menyebabkan masalah gradien yang menghilang (*vanishing gradient*).

Masalah *vanishing gradient* terjadi ketika *neural network* memiliki banyak layer dengan input yang panjang sehingga nilai gradien pada *input layer* memiliki nilai yang lebih kecil dari *output layer*. Ketika memiliki banyak layer maka, nilai bobot saat proses *backpropagation* menjadi kecil sekali atau mendekati nol atau dikatakan menghilang sehingga sinyal gradien akan menjadi lambat atau berhenti untuk bekerja, oleh karena itu terjadilah proses *vanishing gradient*, namun sebaliknya ketika nilai bobot dalam matriks ini besar, menyebabkan sinyal gradien akan sangat besar akibatnya menimbulkan masalah nilai gradien yang meledak (*exploding gradient*).

RNN terdiri dari unit *input*, *output*, dan unit tersembunyi. Ciri dari RNN dalam melakukan suatu prediksi tidak hanya menggunakan *input* satu waktu saja namun membutuhkan masukan dan *input* sebelumnya, oleh karena itu antar *input* saling berhubungan dan dapat memberikan informasi ke *hidden layer* (Sen, dkk., 2020).



Gambar 2. Arsitektur *Recurrent Neural Network*
(Sumber: Tian, dkk., 2018)

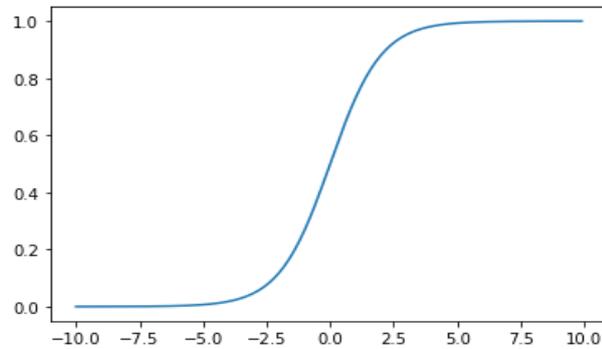
2.7 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang digunakan pada jaringan saraf untuk mengaktifkan atau tidak mengaktifkan neuron (Julpan, dkk., 2015). Fungsi aktivasi yang sering digunakan salah satunya adalah sebagai berikut.

1. Fungsi aktivasi *sigmoid* merupakan fungsi nonlinier yang menampilkan nilai dengan *range* 0 sampai 1, yang artinya menggambarkan banyak masing-masing komponen yang harus dilewati. Fungsi sigmoid ditunjukkan pada persamaan berikut.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

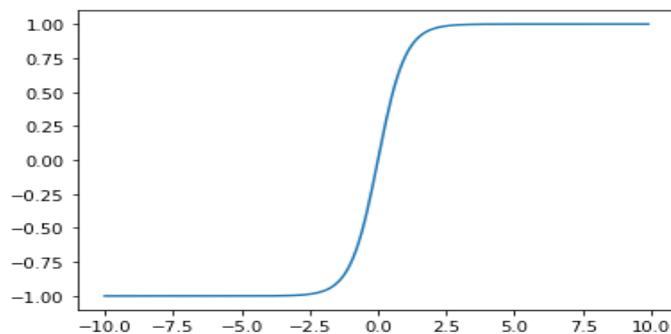
Berikut merupakan grafik dari fungsi aktivasi sigmoid.



Gambar 3. Fungsi Aktivasi Sigmoid

2. Fungsi aktivasi *tangen hiperbolik* atau *tanh* merupakan fungsi alternatif dari lapisan sigmoid. *Input* untuk fungsi aktivasi *tanh* ini berupa bilangan asli dan *outputnya* memiliki *range* -1 sampai 1 dengan persamaan sebagai berikut.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$



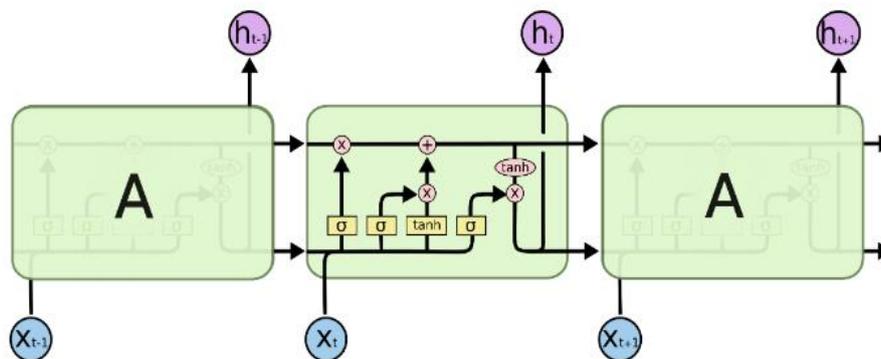
Gambar 4. Fungsi Aktivasi *Tangen Hiperbolik*

Fungsi ini memiliki kekurangan yaitu dapat mematikan *gradient* namun pengaplikasiannya fungsi ini lebih baik dari pada fungsi *sigmoid*.

2.8 Long-Short Term Memory (LSTM)

Long-Short Term Memory merupakan metode yang diusulkan oleh Sepp Hochreiter dan Juergen Schmidhuber pada tahun 1997. *Long-Short Term Memory* merupakan salah satu jenis *machine learning* berbasis pendekatan dari arsitektur *Recurrent Neural Network* yang dapat mengelola data dalam skala besar. LSTM dibangun untuk menangani permasalahan pada RNN, yaitu saat pemrosesan data sekuensial jangka panjang arsitektur RNN tidak dapat belajar menghubungkan informasi karena memori lama yang tersimpan akan semakin tidak berguna dan tertimpa dengan memori baru, sedangkan LSTM dapat mengatasi permasalahan tersebut karena dapat mengatur memori pada setiap masukannya dengan menggunakan *memory cells* dan *gate units* (Arfan dan Lusiana, 2019). Sel LSTM mampu menghubungkan informasi sebelumnya dengan informasi selanjutnya dan keefektifan untuk menyimpan informasi yang panjang sangat diperlukan dalam mengolah data *time series*. Hochreiter dan Schmidhuber (1997), mengusulkan bahwa LSTM dapat mengatasi permasalahan pada meledak dan menghilangnya gradien atau *vanishing gradient*.

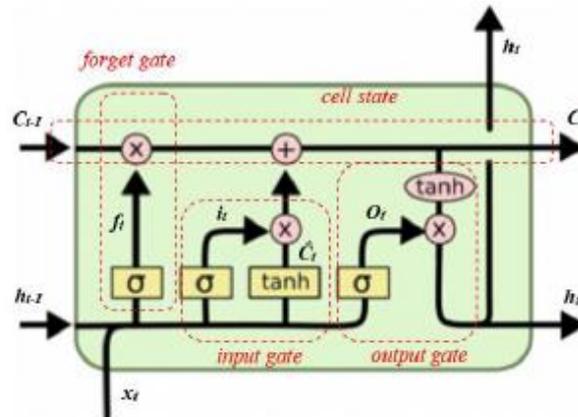
Arsitektur LSTM terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan *output* (Wiranda dan Sadikin, 2019). Berikut merupakan arsitektur LSTM.



Gambar 5. Arsitektur *Long-Short Term Memory*

(Sumber: Hochreiter and Schmidhuber, 1997)

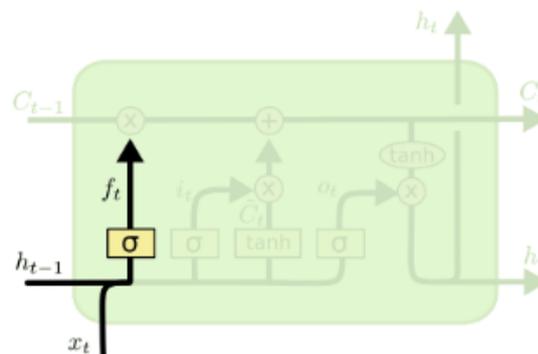
Setiap sel memori pada LSTM memiliki tiga lapisan *sigmoid* dan satu lapisan *tanh*. Pada arsitektur LSTM lapisan tersembunyi terdiri dari sel memori, satu sel memori tersusun atas tiga *gates*, yaitu *forget gate*, *output gate*, dan *input gate* (Vinayukumar, dkk., 2017).



Gambar 6. Sel Memori *Long-Short Term Memory*

Gambar diatas menunjukkan bagian dari lapisan tersembunyi LSTM, yaitu sel memori. Sel memori pada LSTM dapat menyimpan nilai atau keadaan (*cell state*) untuk periode waktu panjang ataupun singkat. Berikut merupakan gerbang yang ada pada satu sel LSTM.

1. *Forget gate* merupakan gerbang yang memutuskan apakah informasi harus dibuang atau tidak dari *cell state*, perhitungan ini menggunakan data *output* sebelumnya h_{t-1} dan data *input* x_t dengan alur yaitu:



Gambar 7. Alur *Forget Gate*

Persamaan *forget gate* diuraikan sebagai berikut.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2.4)$$

dengan:

- f_t = *forgot gate*
- σ = fungsi sigmoid
- W_f = nilai *weight* untuk *forgot gate*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_f = nilai bias pada *forgot gate*

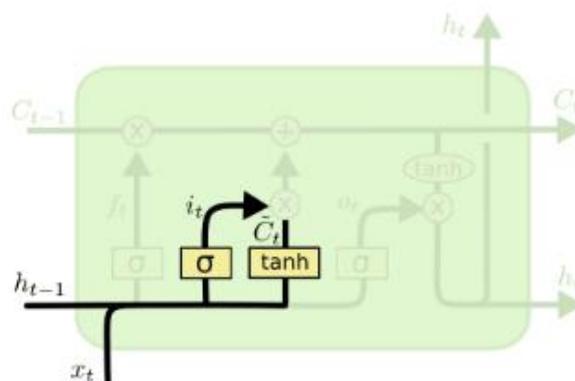
Nilai *weight* dapat dirumuskan sebagai berikut.

$$W = \left(-\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}} \right) \quad (2.5)$$

dengan:

- W = *weight*
- d = jumlah data

2. *Input gate* merupakan gerbang masukan dengan dua fungsi aktivasi (sigmoid dan *tanh*) yang berfungsi untuk memilih bagian yang akan diperbaharui, dengan alur, yaitu:



Gambar 8. Alur *Input Gate*

Persamaan *input gate* diuraikan sebagai berikut.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2.6)$$

dengan:

- i_t = *input gate*
- σ = fungsi sigmoid
- W_i = nilai *weight* untuk *input gate*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_i = nilai bias pada *input gate*

persamaan kandidat baru sebagai berikut.

$$\widetilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (2.7)$$

dengan:

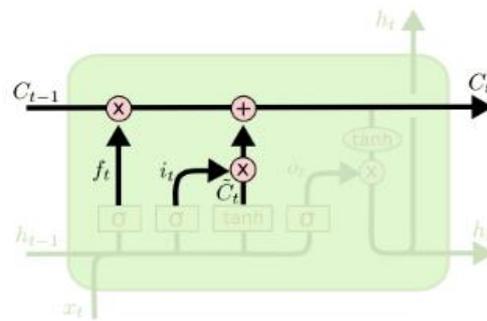
- \widetilde{C}_t = nilai baru yang ditambahkan ke *cell state*
- \tanh = fungsi *tangen hiperbolik*
- W_c = nilai *weight* untuk *cell state*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_c = nilai bias pada *cell state*

Setelah itu *cell state* yang lama akan diperbaharui menjadi *cell state* yang baru dengan mengalikan *state* lama dengan *forgot gate* (f_t) untuk menghapus informasi yang telah ditentukan pada *layer forgot gate* kemudian ditambahkan dengan $i_c * \widetilde{C}_t$ yang merupakan nilai baru untuk memperbaharui *state*, sehingga menghasilkan persamaan *cell state* sebagai berikut.

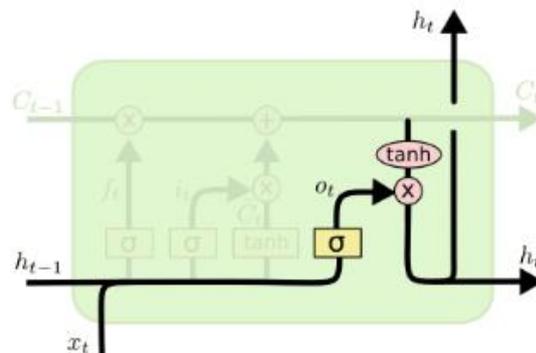
$$C_t = f_t * C_{t-1} + i_t * \widetilde{C}_t \quad (2.8)$$

dengan:

- C_t = *cell state*
- f_t = *forgot gate*
- C_{t-1} = *cell state* sebelum orde ke t
- i_t = *input gate*
- \widetilde{C}_t = nilai baru yang dapat ditambahkan ke *cell state*

Gambar 9. Alur *Cell State* Baru

3. *Output gate* berfungsi untuk memutuskan apa yang akan dihasilkan berdasarkan *input* dan memori blok. *Output* yang dihasilkan harus sesuai dengan *cell state* yang telah diproses sebelumnya. *Output* dari *cell state* dimasukkan ke dalam layer *tanh* dan dikalikan dengan *sigmoid gate* agar *output* yang dihasilkan sesuai dengan yang diputuskan sebelumnya dengan alur yaitu:

Gambar 10. Alur *Output Gate*

Persamaan *output gate* diuraikan sebagai berikut.

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (2.9)$$

dengan:

- o_t = *output gate*
- σ = fungsi sigmoid
- W_o = nilai *weight* untuk *output gate*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_o = nilai bias pada *output gate*

Setelah memperoleh nilai dari *output gate* maka *cell state* ditempatkan melalui *tanh*. Lalu mengalikan dengan *output gate* dan *sigmoid layer*. Persamaan nilai *output* orde ke t pada persamaan sebagai berikut.

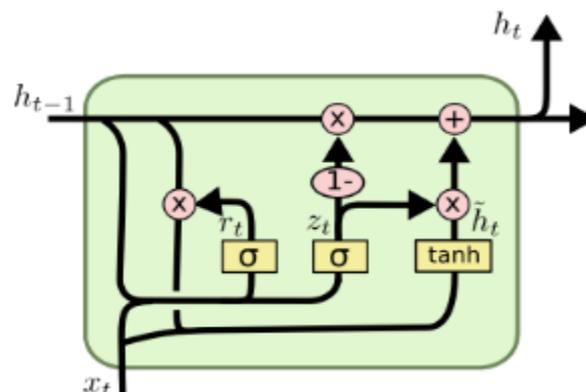
$$h_t = o_t * \tanh(C_t) \quad (2.10)$$

dengan:

- h_t = nilai *output* orde ke t
- o_t = *output gate*
- \tanh = fungsi *tangen hiperbolik*
- C_t = *cell state*

2.9 Gated Recurrent Unit (GRU)

Gated Recurrent Unit merupakan turunan dari *recurrent neural network* yang pertama kali dikenalkan oleh Chung, dkk pada tahun 2014 dan merupakan versi LSTM yang disederhanakan sehingga tidak memerlukan waktu pelatihan dengan kinerja jaringan yang ditingkatkan. Dalam melakukan proses sel GRU mirip dengan pengoperasian sel LSTM, tetapi sel GRU hanya menggunakan satu sel tersembunyi yang menggabungkan *forget gate* dan *input gate* yang dijadikan satu gerbang pembaruan. Gambar berikut merupakan arsitektur GRU.



Gambar 11. Arsitektur *Gated Recurrent Unit*

Didalam GRU komponen pengatur alur informasi disebut dengan *gate*, yang terdiri dari *reset gate* dan *update gate* (Chung, dkk., 2014).

1. *Update gate* digunakan untuk menentukan seberapa banyak informasi masa lalu yang tetap disimpan dengan persamaan berikut:

$$z_t = \sigma(W_z * [h_{t-1}, x_t] + b_z) \quad (2.11)$$

dengan:

- z_t = *update gate*
- σ = fungsi sigmoid
- W_z = nilai *weight* untuk *update gate*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_z = nilai bias pada *update gate*

2. *Reset gate* digunakan untuk menentukan bagaimana akan menggabungkan informasi *input* baru dengan informasi masa lalu dengan persamaan berikut.

$$r_t = \sigma(W_r * [h_{t-1}, x_t] + b_r) \quad (2.12)$$

dengan:

- r_t = *reset gate*
- σ = fungsi sigmoid
- W_r = nilai *weight* untuk *reset gate*
- h_{t-1} = nilai *output* sebelum orde ke t
- x_t = nilai *input* pada orde ke t
- b_r = nilai bias pada *reset gate*

Penentuan kandidat *hidden state* pada *time step* saat ini (t) dan informasi pada masa lalu ($t - 1$) menggunakan fungsi aktivasi *tanh* dengan persamaan sebagai berikut.

$$\tilde{h}_t = \tanh(W * x_t + (r_t * h_{t-1}) * W + b_h) \quad (2.13)$$

dengan:

- \tilde{h}_t = kandidat *hidden state*
- \tanh = fungsi *tangen hiperbolik*
- W = nilai parameter *weight*
- x_t = nilai *input* pada orde ke t
- r_t = *reset gate*

h_{t-1} = nilai *output* sebelum orde ke t
 b_h = nilai bias pada *hidden state*

Proses perhitungan *output* terakhir dengan persamaan sebagai berikut.

$$h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \quad (2.14)$$

dengan:

h_t = *output*
 h_{t-1} = *hidden state* sebelum orde ke t
 z_t = *output* pada *update gate*
 \tilde{h}_t = kandidat *hidden state*

2.10 Denormalisasi Data

Setelah didapatkan hasil prediksi maka sebelum dilakukan perhitungan akurasi hasil prediksi perlu dilakukan denormalisasi, yaitu data diubah menjadi bentuk awal kembali dikarenakan data hasil prediksi masih kedalam bentuk interval pada saat normalisasi data (Ashar, dkk., 2018). Berikut persamaan untuk denormalisasi.

$$X_t = x'(X_{max} - X_{min}) + X_{min} \quad (2.15)$$

dengan:

X_t = nilai hasil denormalisasi
 x' = nilai output data setelah dihasilkan
 X_{max} = nilai maksimal pada data aktual
 X_{min} = nilai minimal pada data aktual

2.11 Evaluasi Model

Makridakis dkk. (1999) menyatakan bahwa, ketepatan atau akurasi menunjukkan seberapa jauh model peramalan tersebut mampu mereproduksi data yang telah diketahui. Ukuran ketepatan model sebagian besar menggunakan faktor kesalahan galat yang diperoleh dari perbedaan antara data aktual dan hasil peramalan.

Untuk melihat akurasi model digunakan ukuran sebagai berikut (Budiman, 2016).

1. *Mean Square Error* (MSE)

Mean Square Error digunakan untuk mengevaluasi metode suatu peramalan yang menghasilkan kesalahan-kesalahan yang kemungkinan lebih baik untuk kesalahan yang kecil, namun menghasilkan perbedaan yang besar. Dengan persamaan sebagai berikut.

$$\text{MSE} = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_t)^2}{n} \quad (2.16)$$

dengan:

Y_i = Data aktual pada periode t

\hat{Y}_t = Data hasil peramalan pada periode t

n = Jumlah periode peramalan yang terlibat

2. *Root Mean Square Error* (RMSE)

Root Mean Square Error digunakan sebagai parameter akurasi dan efisiensi dari setiap algoritma. RMSE digunakan untuk menghitung nilai kesalahan atau perbedaan antara data prediksi dengan aktual. Dengan persamaan sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_t)^2}{n}} \quad (2.17)$$

dengan:

Y_i = Data aktual pada periode t

\hat{Y}_t = Data hasil peramalan pada periode t

n = Jumlah periode peramalan yang terlibat

3. *Mean Absolute Percentage Error* (MAPE)

Berdasarkan Riyadi (2005), MAPE merupakan rata-rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual. MAPE digunakan untuk menghitung persentase kesalahan antara nilai aktual dan nilai prediksi.

MAPE dirumuskan sebagai berikut.

$$100\% \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{Y}_i - Y_i}{Y_i} \right| \quad (2.18)$$

dengan:

Y_i = Data aktual pada periode t

\hat{Y}_i = Data hasil peramalan pada periode t

n = Jumlah periode peramalan yang terlibat

Nilai evaluasi yang dihasilkan oleh MAPE memiliki kriteria sebagai berikut.

- a. $MAPE < 10\%$: kemampuan peramalan sangat baik
- b. $10\% \leq MAPE < 20\%$: kemampuan peramalan baik
- c. $20\% \leq MAPE < 50\%$: kemampuan peramalan cukup
- d. $MAPE \geq 50\%$: kemampuan peramalan buruk

2.12 Inisialisasi Parameter

Proses pembuatan model perlu dilakukan *hypertuning* parameter yang terdiri dari menentukan jumlah *neuron* unit untuk model dan *dropout*. Proses *training* lapisan *dropout* digunakan untuk mencegah terjadinya *overfitting* dan mempercepat proses *learning* (Abhirawa, dkk., 2017). *Early stopping* digunakan untuk menghentikan proses iterasi ketika sudah mencapai nilai yang optimal. Parameter lainnya yang digunakan adalah *epoch* dan *batch size*. *Epoch* terjadi apabila seluruh dataset telah melalui proses *training* pada *neural network* sampai dengan kembali dalam putaran pertama. Satu *epoch* terlalu besar pada proses pelatihan karena memerlukan waktu yang cukup lama. Oleh karena itu, untuk mempercepat maka, dalam proses *training* dilakukan pembagian per *batch* yang disebut *batch size*. *Batch size* merupakan jumlah sampel yang disebar dalam proses *neural network* dan dikatakan efisien ketika komputasi pada data besar. Penentuan *batch size* tergantung pada jumlah sampel (Nur dan Hertantyo, 2018).

III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

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

3.2 Data Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) yang merupakan data *time series* mengenai nilai ekspor migas-nonmigas terhitung sejak periode Januari 1993 sampai dengan Desember 2021 dengan jumlah data sebanyak 348 data masing-masing komponen.

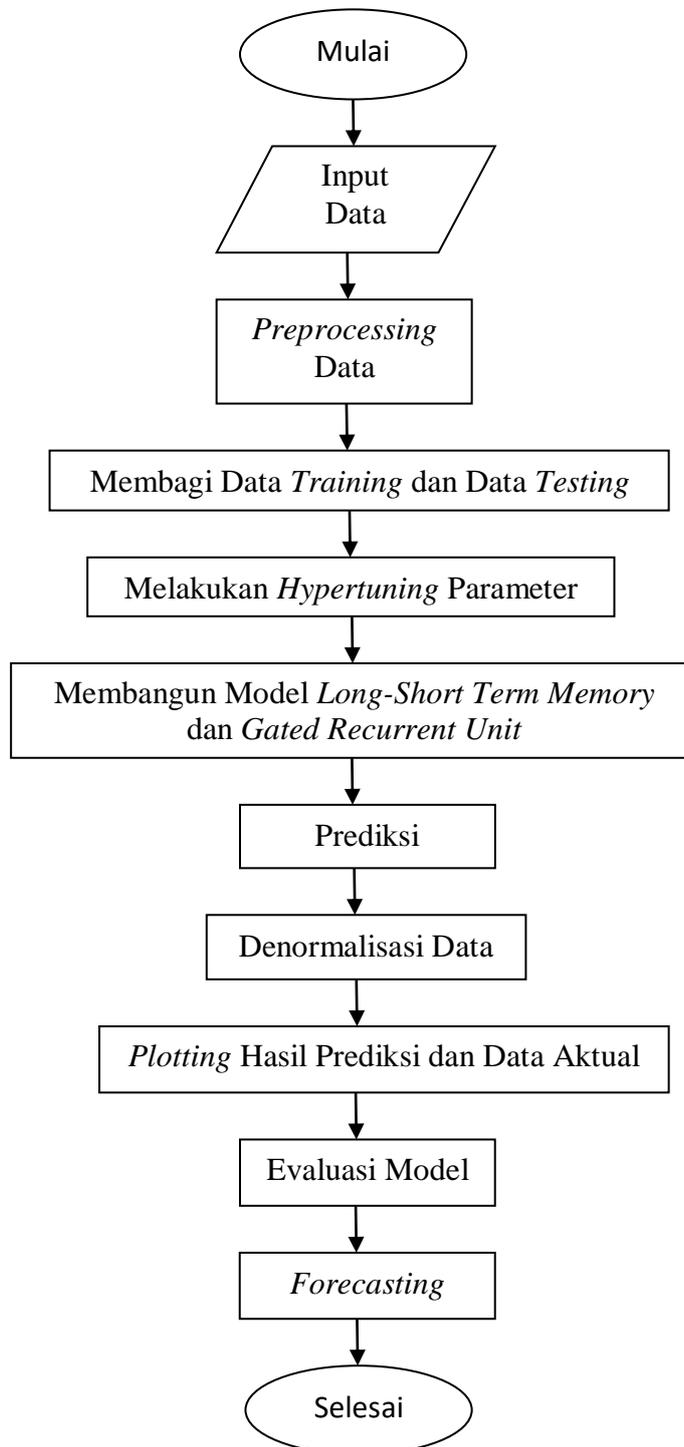
3.3 Metode Penelitian

Pada penelitian ini akan menentukan metode manakah yang terbaik antara *Long Short Term Memory* dan *Gated Recurrent Unit* untuk memprediksi nilai ekspor migas-nonmigas dengan bantuan *Python* pada *Google Colab*.

1. Tahapan penelitian metode *Long Short Term Memory* antara lain:
 - a. Melakukan input data migas-nonmigas
 - b. Melakukan *preprocessing* data, yaitu dengan melakukan normalisasi data menggunakan *min-max normalization*

- c. Melakukan pembagian data yaitu data *training* dan data *testing* dengan pembagian data sebesar 70% sebagai data *training* dan 30% data *testing*
 - d. Menentukan inisialisasi parameter-parameter yang dibutuhkan yaitu *neuron, dropout, batch size*, dan *epoch*
 - e. Membangun model LSTM dengan proses *hypertuning*
 - f. Melakukan prediksi data
 - g. Melakukan proses denormalisasi untuk mengembalikan hasil prediksi agar bisa dibandingkan dengan data aktual
 - h. Membandingkan data hasil prediksi dan aktual dengan *plotting*
 - i. Melakukan evaluasi terhadap model LSTM yang telah dibangun dengan nilai RMSE dan MAPE.
2. Tahapan penelitian metode *Gated Recurrent Unit* antara lain:
- a. Melakukan input data migas-nonmigas
 - b. Melakukan *preprocessing* data, yaitu dengan melakukan normalisasi data menggunakan *min-max normalization*
 - c. Melakukan normalisasi data dengan menggunakan *min-max normalization*
 - d. Melakukan pembagian data yaitu data *training* dan data *testing* dengan pembagian data sebesar 70% sebagai data *training* dan 30% data *testing*
 - e. Menentukan inisialisasi parameter-parameter yang dibutuhkan yaitu *neuron, dropout, batch size*, dan *epoch*.
 - j. Membangun model GRU dengan proses *hypertuning*
 - f. Melakukan prediksi data
 - g. Melakukan proses denormalisasi untuk mengembalikan hasil prediksi agar bisa dibandingkan dengan data aktual
 - h. Membandingkan data hasil prediksi dan aktual dengan *plotting*
 - i. Melakukan evaluasi terhadap model GRU yang telah dibangun dengan nilai RMSE dan MAPE.
3. Perbandingan antara metode *Long Short Term Memory* dan *Gated Recurrent Unit*.
4. Melakukan peramalan untuk menentukan nilai ekspor migas-nonmigas pada tahun 2022-2023.

Dibawah ini merupakan *flowchart* dari kedua metode.



Gambar 12. *Flowchart* Metode LSTM dan GRU

V. KESIMPULAN

Berdasarkan hasil dari pembahasan mengenai metode *Long-Short Term Memory* dan *Gated Recurrent Unit* dapat disimpulkan sebagai berikut.

1. Metode LSTM untuk nilai ekspor komponen migas parameter terbaik dengan menggunakan LSTM unit sebanyak 16, *dropout* sebesar 0,4 dengan *epoch* optimal sebanyak 50 dan komponen nonmigas parameter optimal dengan menggunakan LSTM unit sebanyak 32, *dropout* sebesar 0,4 dengan *epoch* optimal sebanyak 29. Untuk metode GRU untuk nilai ekspor komponen migas parameter terbaik dengan menggunakan GRU unit sebanyak 16, *dropout* sebesar 0,3 dengan *epoch* optimal sebanyak 50 dan komponen non migas parameter optimal dengan menggunakan GRU unit sebanyak 16, *dropout* sebesar 0,3 dengan *epoch* optimal sebanyak 50.
2. Untuk ketepatan dalam prediksi komponen migas dan non-migas untuk metode LSTM memiliki nilai MAPE sebesar 0,9998% dan 0,9999% dan metode GRU memiliki nilai MAPE sebesar 0,9998% dan 0,9999% yang artinya, nilai MAPE dari kedua metode kurang dari 10% dimana menunjukkan kemampuan prediksi nilai ekspor migas dan nonmigas sangat baik.
3. Berdasarkan hasil evaluasi model dengan RMSE, metode GRU merupakan metode terbaik untuk kedua komponen dengan nilai sebesar 0,0655 untuk komponen migas, sedangkan sebesar 0,0697 untuk komponen nonmigas.
4. Hasil peramalan yang diperoleh pada periode 2022 sampai 2023 untuk metode LSTM mengalami kenaikan baik untuk komponen migas ataupun nonmigas, sedangkan untuk metode GRU terlihat mengalami penurunan.

DAFTAR PUSTAKA

- Abhirawa, H., Jondri, dan Arfianto A. 2017. Face Recognition Using Convolution Neural Network. *E-Proceeding Engineering*. 4(3): 4907-4916.
- Aldi, M.W., Jondri, dan Aditsania A. 2018. Analisis dan Implementasi Long-Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *E-Proceeding Engineering*. 5(2): 3548-3555.
- Arfan, A., dan Lussiana, E. T. P. 2019. Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory. *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi*, 3(1): 225–230.
- Arunkumar, K.E., Kalaga, D., Kumar, C. M., Kawaji, M, and Brenza, T. 2021. Forecasting of COVID 19 Using Deep Layer Recurrent Neural Networks (RNNs) with Gated Recurrent Unit (GRUs) and Long Short Term Memory (LSTM) Cells. *Chaos, Solitons & Fractals Journal*. 146.
- Ashar, N. M., Cholissodin, I., dan Dewi,C. 2018. Penerapan Metode Extreme Learning Machine (ELM) untuk Memprediksi Jumlah Produksi Pipa yang Layak (Studi Kasus pada PT. KHI Pipe Industries). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(11): 4621–4628.
- Budiman, H. 2016. Analisis dan Perbandingan Akurasi Model Prediksi Rentet Waktu Support Vector Machines Dengan Support Vector Machines Particle Swarm Optimization Untuk Arus Lalu Lintas Jangka Pendek. *Systemic: Information System and Informatics Journal*, 2(1): 19–24.
- Chung, J., Gulcehre, C., Cho, K., and Bengio Y. 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv*, 1-9.
- Fauziah, N., Wahyuningsih, S., dan Nasution, Y.N. 2016. Peramalan Menggunakan Fuzzy Time Series Chen (Studi Kasus : Curah Hujan Kota Samarinda). *Jurnal Statistika Universitas Muhammadiyah Semarang*. 4(2): 52-61.
- Fayyad, U. 1996. *Advances in Knowledge Discovery and Data Mining*. MIT Press, USA.

- Hanke, J.E. and Wichern, D.W. 2005. *Business Forecasting. Eight Edition.* Pearson Prentice Hall, New Jersey.
- Hastomo, W., Karno, A.S., Kalbuana, N., Nisfiani, E., dan Lussiana. 2021. Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19. *Jurnal Edukasi dan Penelitian Informatika.* **7(2)**: 133-140.
- Heizer, J. and Render, B. 1996. *Operations Management.* Prentice Hall, New Jersey.
- Hochreiter, S. and Schmidhuber, J. 1997. Long Short-Term Memory. *Neural Computation.* **9(8)**: 1735-1780.
- Julpan, Budhiarti, E., dan Zarlis, M. 2015. Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar Dalam Algoritma Backpropagation pada Prediksi Kemampuan Mahasiswa. *Jurnal Teknik dan Inovasi Mesin Otomotif, Komputer, Industri dan Elektronika.* **2(1)**: 103-116.
- Kusrini dan Emha, T.L. 2009. *Algoritma Data Mining.* CV Andi Offset, Yogyakarta.
- Lewis, N.D. 2017. *Neural Network For Time Series Forecasting With R.* Pearson Education, New York.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan.* Edisi ke-2. Erlangga, Jakarta.
- Nur, A. dan Hertantyo, G.B. 2018. Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Jurnal Teknik Elektro.* **18(1)**: 15-21.
- Riyadi,S. 2015. Aplikasi Peramalan Penjualan Obat Menggunakan Metode Pemulusan (Studi Kasus:Instalasi Farmasi Rsud Dr Murjani). *Open Journal System Universitas AMIKOM.* (1): 1-6.
- Russel, S. J. and Norvig, P. 2016. *Artificial Intelligence: A Modern Approach.* Pearson Education Limited, Malaysia
- Saputra, R. A., Azhar, Y, dan Rahmayanti, V. 2020. Prediksi Permintaan Kargo pada Cargo Service Center Tangerang City Menggunakan Metode Gated Recurrent Unit. *Jurnal Repositor.* **2(8)**: 1113-1122.
- Sen, S., Sugiarto, D., dan Rochman, A. 2020. Komparasi Metode Multilayer Perceptron (MLP) dan Long-Short Term Memory (LSTM) dalam Peramalan Harga Beras. *Jurnal Teknik Informatika.* **11(1)**: 35-41.

- Tian, C., Ma, J.,Zhang, C., dan Zhan, P. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long-Short Term Memory Network and Convolution Neural Network. *Energies Journal*. **11**: 1-13.
- Vinayakumar,R., Soman, K.P., and Poornachandran, P. 2017. Long Short-Term Memory Based Operation Log Anomaly Detection. *International Conference Advance Computing Communication Informatics*, 236–242.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. 2nd Edition. Addison Wesley Publishing Company, New York.
- Wiranda, L. dan Sadikin, M. 2019. Penerapan Long Short Term Memory Pada Data *Time Series* Untuk Memprediksi Penjualan Produk Pt. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*. **8**(3): 184-196.
- Zhang, G. P. 2004. *Neural Network in Business Forecasting*. Idea Group Publishing, USA.