

SKRIPSI

**IMPLEMENTASI LONG SHORT TERM MEMORY
UNTUK MEMPREDIKSI HARGA
MINYAK KELAPA SAWIT INTERNASIONAL**

**Oleh :
Muhamad Fahry Saputra
065118012**



**PROGRAM STUDI ILMU KOMPUTER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS PAKUAN
BOGOR
2024**

SKRIPSI

IMPLEMENTASI LONG SHORT TERM MEMORY UNTUK MEMPREDIKSI HARGA MINYAK KELAPA SAWIT INTERNASIONAL

Diajukan sebagai salah satu syarat untuk memperoleh
Gelar Sarjana Komputer Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam

Oleh :
Muhamad Fahry Saputra
065118012



**PROGRAM STUDI ILMU KOMPUTER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS PAKUAN
BOGOR
2024**

HALAMAN PERSEMBAHAN

“Kebahagiaan ada di dalam, ini tidak ada hubungan dengan seberapa banyak tepuk tangan yang kamu berikan atau berapa banyak orang yang memujimu. Kebahagiaan datang ketika kamu yakin bahwa kamu telah melakukan sesuatu yang benar-benar berarti.”

~ Martin Yan ~

HALAMAN PENGESAHAN

Judul : Implementasi Long Short Term Memory Untuk Memprediksi Harga Minyak Kelapa Sawit Internasional
Nama : Muhamad Fahry Saputra
Npm : 065118012

Mengesahkan,

Pembimbing Pendamping
FMIPA - UNPAK



Syarif Hidayatullah, M.Kom

Pembimbing Utama
FMIPA - UNPAK



Dr. Hermawan Taher

Mengetahui,

Ketua Program Studi Ilmu Komputer
FMIPA - UNPAK



Arie Qur'ania, M.Kom

Dekan
FMIPA - UNPAK



Asep Denih, S.Kom., M.Sc., Ph.D.

PERNYATAAN KEASLIAN KARYA TULIS SKRIPSI

Dengan ini saya menyatakan bahwa:

Sejauh yang saya ketahui, karya tulis ini bukan merupakan karya tulis yang pernah dipublikasikan atau sudah pernah dipakai untuk mendapatkan gelar sarjana di Universitas lain, kecuali pada bagian-bagian di mana sumber informasinya dicantumkan dengan cara refrensi yang semestinya.

Demikian pernyataan ini saya buat dengan sebenar-benarnya. Apabila kelak dikemudian hari terdapat gugatan, penulis bersedia dikenakan sanksi sesuai dengan peraturan yang berlaku.

Bogor, 9 Januari 2024



Muhamad Fahry Saputra

PERNYATAAN PELIMPAHAN SKRIPSI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Saya yang bertandatangan di bawah ini :

Nama : Muhamad Fahry Saputra
NPM : 065118012
Judul Skripsi : Implementasi Long Short Term Memory Untuk
Memprediksi Harga Minyak Kelapa Sawit Internasional

Dengan ini saya menyatakan bahwa Paten dan Hak Cipta dari produk Skripsi dan Tugas Akhir di atas adalah benar karya saya dengan arahan dari komisi pembimbing dan belum diajukan dalam bentuk apapun kepada perguruan tinggi manapun.

Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir skripsi ini.

Dengan ini saya melimpahkan Paten, hak cipta dari karya tulis saya kepada Universitas Pakuan.

Bogor, 9 Januari 2024



Muhamad Fahry Saputra

RIWAYAT HIDUP

Muhamad Fahry Saputra adalah mahasiswa kelahiran Bogor, 08 November 2000 dan merupakan anak kedua dari tiga bersaudara. Penulis mengawali pendidikan dasar di SD IT Asy-Syifa Qolbu, melanjutkan jenjang pendidikan ke SMPN 2 Gunung Putri dan menyelesaikan pendidikan di SMA Bina Bangsa Mandiri. Kemudian penulis melanjutkan studi ke perguruan tinggi yaitu di Universitas Pakuan dengan program studi Ilmu Komputer, dan menyelesaikan studi pada bulan Desember 2023 dengan menyelesaikan penelitian dengan judul Implementasi *Long Short Term Memory* (LSTM) Untuk Memprediksi Harga Minyak Kelapa Sawit Internasional.

RINGKASAN

Penelitian ini menggunakan *Long Short Term Memory* (LSTM) untuk memprediksi harga minyak kelapa sawit (CPO). metode yang akan digunakan adalah *Cross Industry Standard Process For Data Mining* (CRIPS-DM) yang memiliki 6 tahapan yang meliputi *Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment*. Penelitian ini bertujuan untuk membuat model prediksi harga minyak kelapa sawit di waktu yang akan datang untuk memastikan bahwa harga yang diprediksi tidak terlalu jauh dari harga yang akan terjadi dan investor tidak mengalami kerugian yang besar. Diawali memperoleh data histori yang diambil dari website Investing.com dengan periode Januari 2017 hingga Desember 2022. Selanjutnya, model prediksi LSTM dibangun dengan bantuan Google Colaboratory. Kemudian, untuk menemukan model dengan tingkat akurasi yang optimal Pengujian dilakukan dengan nilai *Epoch* bervariasi termasuk *Epoch* 10, 20, 30, 40, 50, 60, 70 dan *Epoch* 100, 150, 200, 250, 300. Dan secara keseluruhan, pengujian menunjukkan tingkat akurasi yang sangat baik pada *Epoch* 60 dengan hasil prediksi harga minyak kelapa sawit di waktu yang datang dengan akurasi MAPE setiap variabel yaitu *Price* 2,91%, *High* 4,61%, *Low* 2,72%.

KATA PENGANTAR

Segala puji syukur kehadirat Allah SWT, yang telah memberikan rahmatnya terutama nikmat Kesehatan. Saya dapat menyelesaikan laporan skripsi dengan judul **“Implementasi *Long Short Term Memory* Untuk Memprediksi Harga Minyak Kelapa Sawit Internasional”**

Dalam penulisan tugas akhir ini, saya dengan senang hati ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. Dr. Hermawan Taher selaku dosen pembimbing utama yang selalu memberikan bimbingan serta motivasi kepada penulis
2. Syarif Hidayatullah, M.Kom selaku dosen pembimbing pendamping yang selalu memberikan bimbingan serta motivasi kepada penulis.
3. Arie Qur`ania, M.Kom selaku ketua program studi Ilmu Komputer FMIPA Universitas Pakuan.
4. Kedua orang tua yang selalu memberikan doa, motivasi, dan dukungan yang tidak ada hentinya sehingga dapat menyelesaikan laporan penelitian ini.
5. Teman-teman seperjuangan yang tidak bisa disebutkan satu-satu yang selalu memberikan dukungan dan semangat kepada penulis.
6. Teman-teman CAKAP SANTUY yang selalu memberikan dukungan serta motivasi dan sebagai tempat curhat.
7. Serta seluruh pihak yang tidak dapat saya sebutkan satu-persatu yang telah memberikan segala dukungan, semangat serta motivasi baik secara langsung maupun tidak langsung.

Penulis menyadari memiliki keterbatasan dalam penyusunan laporan penelitian ini masih jauh dari kata sempurna. Oleh karena itu, segala kritik dan saran yang dapat membangun akan diterima dengan senang hati. Mudah-mudahan Allah SWT akan membalas semua kebaikan kepada semua pihak yang telah membantu. Akhir kata, semoga laporan skripsi ini dapat bermanfaat bagi kita semua.

Bogor, 25 November 2023

Penulis

DAFTAR ISI

	Halaman
HALAMAN PERSEMBAHAN	i
HALAMAN PENGESAHAN.....	ii
PERNYATAAN KEASLIAN KARYA TULIS SKRIPSI.....	iii
PERNYATAAN PELIMPAHAN SKRIPSI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA	iv
RIWAYAT HIDUP	v
RINGKASAN	vi
KATA PENGANTAR.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL	x
DAFTAR GAMBAR.....	xi
DAFTAR LAMPIRAN	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Tujuan.....	2
1.3 Ruang Lingkup.....	2
1.4 Manfaat	3
BAB II TINJAUAN PUSTAKA.....	4
2.1 Landasan Teori	4
2.1.1 Prediksi	4
2.1.2 Minyak Kelapa Sawit (CPO)	4
2.1.3 Fluktuasi Harga	4
2.1.4 Deep Learning.....	5
2.1.5 Python	5
2.1.6 Normalisasi	5
2.1.7 Denormalisasi	6
2.1.8 Long Short Term Memory (LSTM)	6
2.1.9 RMSE dan MAPE.....	10
2.2 Penelitian Terdahulu.....	11
2.3 Tabel Perbandingan Penelitian	13
BAB III METODOLOGI PENELITIAN	14
3.1 Metode Penelitian.....	14
3.1.1 Business Understanding.....	14
3.1.2 Data Understanding	14
3.1.3 Data Preparation	14
3.1.4 Modelling.....	15
3.1.5 Evaluation	15
3.1.6 Deployment.....	15
3.2 Waktu dan Tempat Penelitian.....	15
3.3 Alat dan Bahan	15
3.3.1 Alat.....	15
3.3.2 Bahan	15
BAB IV PERANCANGAN DAN IMPLEMENTASI	16
4.1 Perancangan Sistem	16
4.1.1 Business Understanding.....	16

4.1.2	Data Understanding	16
4.1.3	Data Preparation	16
4.1.4	Modelling.....	19
4.1.5	Evaluation	23
4.1.6	Deployment.....	25
4.2	Implementasi	25
BAB V HASIL DAN PEMBAHASAN		27
5.1	Hasil	27
5.1.1	Data Preparation	27
5.1.2	Modelling.....	28
5.1.3	Evaluation	28
5.2	Pembahasan.....	28
5.2.1	Hasil Akurasi Penngujian Model	29
5.2.1.1	Hasil Pengujian Variabel Price	29
5.2.1.2	Hasil Pengujian Variabel High	30
5.2.1.3	Pengujian Variabel Low	31
5.2.2	Prediksi 5 Minggu Mendatang.....	32
BABVI KESIMPULAN DAN SARAN		34
6.1	Kesimpulan	34
6.2	Saran.....	34
DAFTAR PUSTAKA		35
LAMPIRAN		38

DAFTAR TABEL

	Halaman
Tabel 1. Harga CPO 2020 - 2022	4
Tabel 2. Nilai MAPE	11
Tabel 3. Penelitian Terdahulu	13
Tabel 4. Variabel Yang Digunakan	16
Tabel 5. Normalisasi Data Sampel Variabel Price	18
Tabel 6. Normalisasi Data Sampel Variabel High	19
Tabel 7. Normalisasi Data Sampel Variabel Low	19
Tabel 8. Forget Gate	20
Tabel 9. Input Gate	20
Tabel 10. Cell State	21
Tabel 11. Output Gate dan Hidden State	21
Tabel 12. Output Hidden State	22
Tabel 13. Denormalisasi Data	23
Tabel 14. Pembagian Data Training dan Test	27
Tabel 15. Arsitektur dan Parameter	28
Tabel 16. Pengujian Variabel Price	29
Tabel 17. Pengujian Variabel High	30
Tabel 18. Pengujian Variabel Low	31
Tabel 19. Hasil Prediksi 5 Minggu Mendatang	32

DAFTAR GAMBAR

	Halaman
Gambar 1. Fluktuasi Harga CPO.....	5
Gambar 2. Struktur LSTM	7
Gambar 3. Memori LSTM	7
Gambar 4. Forget Gate	7
Gambar 5. Input Gate	8
Gambar 6. Cell State	9
Gambar 7. Output Gate	9
Gambar 8. Tahapan CRISP-DM.....	14
Gambar 9. Menghapus variabel.....	16
Gambar 10. Pemanggilan library python	17
Gambar 11. Mengubah tipe data.....	17
Gambar 12. Pembagian Data Training Dan Test.....	18
Gambar 13. Implementasi Google Colaboratory	26
Gambar 14. Visualisasi Variabel Penelitian.....	27
Gambar 15. Proses Normalisasi	28
Gambar 16. Visualisasi Grafik Price	30
Gambar 17. Visualisasi Grafik High	31
Gambar 18. Visualisasi Grafik Low	32

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Dataset Mingguan 2017 - 2022	39
Lampiran 2. Data Normalisasi Pada Variabel Price, High, Low.....	46

BAB I

PENDAHULUAN

1.1 Latar Belakang

Minyak kelapa sawit, juga dikenal sebagai *Crude Palm Oil* (CPO) adalah olahan minyak yang berasal dari buah kelapa sawit sebagai komoditas ekspor utama Indonesia dan menjadi sumber devisa terbesar. Menurut data dari Badan Pusat Statistik (BPS), jumlah lahan perkebunan kelapa sawit di Indonesia pada tahun 2019 adalah 14.456,60 hektar dan meningkat menjadi 14.663,60 hektar pada tahun 2021. Ini adalah hasil dari kondisi geografis yang ideal untuk perkebunan kelapa sawit di Indonesia. Dengan peningkatan konsumsi minyak nabati di seluruh dunia, kebutuhan akan minyak kelapa sawit terus meningkat karena peran pentingnya sebagai bahan bakar nabati untuk mengurangi dampak pemanasan global.

Di Indonesia, minyak kelapa sawit atau minyak nabati digunakan untuk membuat bahan bakar B40 yang merupakan bahan bakar minyak (BBM) berjenis solar yang ditambahkan dengan 40% *Fatty Acid Methyl Ester* (FAME). Bahan bakar ini digunakan dalam upaya Indonesia untuk mengurangi impor bahan bakar minyak. Saat menerapkan campuran energi baru terbarukan (EBT) yang memiliki potensi untuk mengurangi emisi karbon,

Selain itu, peluang terhadap investasi minyak kelapa sawit sangatlah positif karena permintaan yang terus meningkat secara signifikan dari tahun ke tahun. Karena sebagian besar negara pengimpor menggunakan minyak kelapa sawit sebagai sumber energi sebagai pengganti minyak bumi. Namun, harga minyak kelapa sawit yang bisa mengalami kenaikan atau penurunan setiap hari karena beberapa faktor. Tetapi, dalam strategi investasi seorang investor harus memiliki kemampuan untuk menciptakan portofolio dengan risiko kecil sekaligus mencapai tingkat pengembalian atau mendapatkan keuntungan yang tinggi dalam strategi investasi mereka.

Selanjutnya, investor perlu dalam melakukan pengamatan atau prediksi terhadap harga minyak kelapa sawit, karena harga yang *berfluktuasi* atau tidak tetap dan dapat berubah setiap harinya. Namun, prediksi harga dengan cara konvensional, dapat meningkatkan resiko dalam berinvestasi. Investor sangat membutuhkan sebuah sistem yang dapat memprediksi harga minyak kelapa sawit sehingga mereka dapat mempertimbangkan harga serta mengurangi resiko dalam berinvestasi.

Algoritma *deep learning* adalah salah satu sistem yang dapat digunakan. Ini adalah jenis pembelajaran *machine learning* yang memungkinkan algoritma untuk mempelajari data sebelumnya dengan menggunakan algoritma yang sudah ada. Proses *deep learning* dapat dilakukan dalam tiga cara meliputi terarah yaitu algoritma dapat mempelajari berdasarkan data yang tersedia, semi terarah yaitu algoritma dapat mempelajari berdasarkan data yang tersedia tetapi tidak mencukupi, dan tidak terarah yaitu algoritma dapat mempelajari berdasarkan data yang tidak tersedia. Dalam situasi seperti ini, algoritma harus dapat menemukan pola masalah yang tersembunyi (Supriyadi, 2021). Salah satu algoritma *deep learning* ialah *Long Short Term Memory* (LSTM).

Long Short Term Memory (LSTM) memiliki kemampuan untuk memodelkan deret waktu atau *time series*. Berdasarkan tingkat kesalahan yang dihasilkan, LSTM dapat dikatakan akurat dalam memprediksi. Hasil yang dihasilkan lebih baik seiring dengan tingkat kesalahan yang lebih kecil (Firdaus, 2023).

Seperti penelitian yang dilakukan oleh Arfan dan ETP, (2020). Dalam penelitiannya membandingkan *Long Short Term Memory* dan SVR untuk prediksi harga saham. dijelaskan hasil prediksi dengan rentang waktu, dimana SVR semakin besar rentang data yang digunakan semakin besar nilai MSE yang dihasilkan. Sedangkan LSTM dengan rentang data yang sama, dapat menghasilkan nilai MSE yang tetap sama dalam memprediksi harga saham.

Penelitian dilakukan oleh Yoga dan Nunu, (2019). Dalam penelitian klasifikasi investasi pada resiko investasi minyak kelapa sawit menggunakan algoritma naive bayes. Hasil prediksi yang didapatkan dengan menggunakan naive bayes pada tahun 2019 mendapatkan nilai *Accuracy* 92,00%, *Recall* 95,83%, dan *Precision* 88,46%.

Penelitian yang dilakukan oleh Rizkilloh dan Widiyanesti, (2022). Dengan menerapkan *Long Short Term Memory* (LSTM) untuk memprediksi harga *cryptocurrency*. Karena kemampuan LSTM untuk menyimpan data jangka pendek dan jangka panjang, dapat memprediksi dengan data *time series*. Hasil pengujian performa terbaik pada koin jenis DOGE menghasilkan nilai RMSE sebesar 0,0630.

Penelitian yang dilakukan Riyantoko et al., (2020). Melakukan penelitian memprediksi harga saham pada sektor perbankan menggunakan algoritma *Long Short Term Memory* (LSTM). Hasil penelitian menunjukkan bahwa algoritma LSTM dapat menunjukkan nilai akurasi yang baik pada nilai RMSE dalam model data yang dibuat dari berbagai nilai *epoch*. Seperti halnya pada variasi *epoch* 25, 50, 75, dan 100, saham BNI menerima RMSE terkecil, yang adalah 139,12 pada *epoch* 75.

Berdasarkan penelitian yang telah dilakukan, dengan masalah yang terkait. Maka penelitian ini akan membangun model algoritma *Long Short Term Memory* (LSTM) untuk memprediksi harga pada minyak kelapa sawit atau CPO (Crude Palm Oil). Dengan melakukan evaluasi tingkat kesalahan menggunakan *Root Mean Square Error* (RMSE) serta tingkat keakuratan menggunakan *mean Absolute Percentange Error* (MAPE) dengan model data yang dibangun dengan nilai *epoch* yang bervariasi agar mendapatkan tingkat kesalahan dan keakuratan yang lebih baik, sehingga dapat membantu investor untuk mengurangi resiko dalam berinvestasi minyak kelapa sawit.

1.2 Tujuan

Tujuan dari penelitian ini adalah Implementasi *Long Short Term Memory* (LSTM) untuk Memprediksi Harga Minyak Kelapa Sawit Internasional.

1.3 Ruang Lingkup

Adapun ruang lingkup pada penelitian dibatasi, meliputi:

- Data diperoleh dari website id.investing.com dengan kata kunci *Palm Oil*
- Data yang digunakan dari tahun 2017 sampai 2022 dengan periode mingguan.
- Data yang digunakan ialah 3 variabel meliputi *Price* (harga terakhir), *High* (harga tertinggi), *Low* (harga terendah).
- Menggunakan algoritma *Long Short Term Memory* (LSTM).
- Data training 80% dan data uji 20%.
- Menggunakan evaluasi model *Root Mean Square Error* (RMSE) untuk mengukur tingkat kesalahan dan *Mean Absolute Percentange Error* (MAPE) untuk tingkat keakuratan.

- g. Implementasi dengan Google *Colaboratory*, Bahasa pemrograman Python.
- h. Hasil dalam bentuk Grafik.

1.4 Manfaat

Adapun manfaat pada penelitian ini sebagai berikut:

- a. Dapat membantu investor untuk memprediksi harga minyak kelapa sawit.
- b. Dapat mengetahui kemampuan algoritma *Long Short Term Memory* (LSTM) dalam memprediksi harga.
- c. Dapat menjadi bahan referensi bagi peneliti selanjutnya yang berkaitan dengan model *Long Short Term Memory* (LSTM).

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Prediksi

Prediksi merupakan upaya meramalkan atau salah satu faktor yang dapat membantu dalam pengambilan keputusan yang tepat, pengambilan keputusan menggunakan prediksi didasarkan data lampau atau data pada saat ini sehingga dapat menggambarkan kondisi yang sesuai dengan sasaran yang dicapai (Sanjaya & Heksaputra, 2020).

2.1.2 Minyak Kelapa Sawit (CPO)

Kelapa sawit merupakan salah satu produk perkebunan yang memainkan peran penting dalam kegiatan perekonomian dan memberikan keuntungan besar bagi Indonesia. Ini karena kemampuan untuk menghasilkan minyak kelapa sawit (minyak nabati), yang memiliki banyak manfaat yang diperlukan oleh sektor industri. Namun demikian, harga minyak kelapa sawit (CPO) yang tidak stabil sangat berdampak bagi investor (Saadah, 2021). Seperti halnya harga CPO dari 2020 hingga 2022, yang mengalami kenaikan yang signifikan pada tahun 2022 dibandingkan pada tahun-tahun sebelumnya, seperti yang ditunjukkan pada tabel 1.

Tabel 1. Harga CPO 2020 - 2022


Bulan	2020 (US \$)	2021 (US \$)	2022 (US \$)
January	855	1065	1305
February	760	1060	1402
March	637	1110	1757
April	590	1090	1660
May	520	1240	1660
June	550	1130	1750
July	582	1060	1505
August	692	1220	1100
September	700	1207	1165
October	775	1305	935
November	750	1400	1120
December	900	1280	1030

Sumber : Bappebti (Badan Pengawas Perdagangan Berjangka Komoditi)

2.1.3 Fluktuasi Harga

Fluktuasi juga dikenal pergeseran adalah perubahan pada suatu variabel yang terjadi karena beberapa mekanisme. Misalnya, harga naik atau turun karena adanya penawaran (supply) dan permintaan (demand) di pasar. Faktor-faktor seperti politik,

ekonomi dan lainnya yang dapat menyebabkan *fluktuasi* ini terjadi (Qothrunnada, 2022). Salah satunya adalah komoditas minyak kelapa sawit (CPO), yang ditunjukkan pada grafik di mana harga CPO stabil pada US\$ dan Ringgit dari 2017 hingga 2020. Namun, pada tahun 2021 terjadi peningkatan harga, dengan puncak terjadi pada awal tahun 2022 dengan CPO US\$ menyentuh harga 1700\$ dan CPO ringgit menyentuh harga 7500 ringgit, dan harga kembali turun pada pertengahan tahun 2022. *Fluktuasi* harga minyak kelapa sawit (CPO) dapat dilihat pada gambar 1.



Gambar 1. Fluktuasi Harga CPO

2.1.4 Deep Learning

Deep Learning adalah bagian dari *machine learning* yang dapat melakukan prediksi lebih akurat dengan pemodelan yang lebih sedikit, namun membutuhkan waktu komputasi yang lebih besar (Sanjaya dan Budi, 2020).

Cara kerja *deep learning* yang meniru fungsi otak manusia melalui penggunaan jaringan saraf tiruan dengan berbagai tingkat *abstraksi* dan berbagai lapisan pemrosesan. *Deep learning* memiliki kemampuan untuk menetapkan nilai secara akurat dalam berbagai tahapan untuk berbagai tujuan seperti unsupervised (tidak terarah), supervised (terarah), dan semi-supervised (semi terarah) sebagai algoritma untuk pengenalan gambar, pengenalan suara, dan juga klasifikasi teks (Aprian et al., 2020).

2.1.5 Python

Python adalah bahasa pemrograman *open source* gratis yang memiliki *source code* yang berorientasi, semantik, dan interpretative serta tanpa batasan penyalinan. *Python* dapat menunjukkan korelasi dalam numberik dan peta warna dan memiliki tampilan grafik yang mudah dibaca dan menarik (Hastomo et al., 2021).

Bahasa pemrograman *python* berbasis *machine learning* yang bersifat dinamis, interaktif, dan berbasis objek. *Python* juga mempunyai banyak *library* yang mudah untuk digunakan seperti *numpy* (untuk vector dan matrik), *pandas* (untuk menganalisis data), *keras* (API deep learning yang berjalan diatas *machine learning TensorFlow*), *matplotlib* (untuk visualiasi data grafik), dan masih banyak lagi.

2.1.6 Normalisasi

Normalisasi merupakan proses menghilangkan nilai null pada data dengan mengubah ukuran data dalam rentang yang lebih kecil. Normalisasi perlu dilakukan karena *Long Short Term Memory* (LSTM) berkerja dengan fungsi sigmoid yang mempunyai range [0,1], sehingga dapat meminimalisir terjadinya error (Lubis & Lubis, 2021).

Normalisasi dilakukan dengan menggunakan metode Min-Max Scaling yaitu menskalakan data dalam rentang tertentu sesuai dengan nilai minimum dan nilai maksimum, sehingga data berada dalam rentang range 0 – 1. Persamaan normalisasi dapat dilihat pada persamaan 1.

$$X' = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Keterangan :

X' = Nilai normalisasi

X_i = Nilai aktual yang dinormalisasi

X_{min} = Nilai minimum dari data aktual

X_{max} = Nilai maksimum dari data aktual

2.1.7 Denormalisasi

Denormalisasi adalah proses mengubah data hasil prediksi yang masih berbentuk nilai dalam rentang 0-1 menjadi nilai aktual. Tujuan denormalisasi adalah untuk membuat hasil prediksi lebih mudah dibaca dan dipahami, dan untuk membandingkan hasil prediksi dengan harga aktual untuk mengetahui kesalahan prediksi (Budiprasetyo et al., 2022). Persamaan denormalisasi dapat dilihat pada persamaan 2.

$$X_t = X (X_{max} - X_{min}) + X_{min} \quad (2)$$

Keterangan :

X_t = Nilai denormalisasi

X = Nilai hidden state

X_{max} = Nilai maksimal aktual


X_{min} = Nilai minimum aktual

2.1.8 Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) merupakan turunan *Recurrent Neural Network* (RNN) yang telah diusulkan oleh Jurgen Schmidhuber dan Sepp Hochreiter dari tahun 1997. Dengan memiliki memori jangka panjang, LSTM dapat mengatasi ketergantungan data jangka panjang dan mengatasi masalah vanishing gradient yang ada di RNN. Selain itu, LSTM juga dapat mengingat dan memahami data dalam bentuk deret waktu (Ericko et al., 2023).

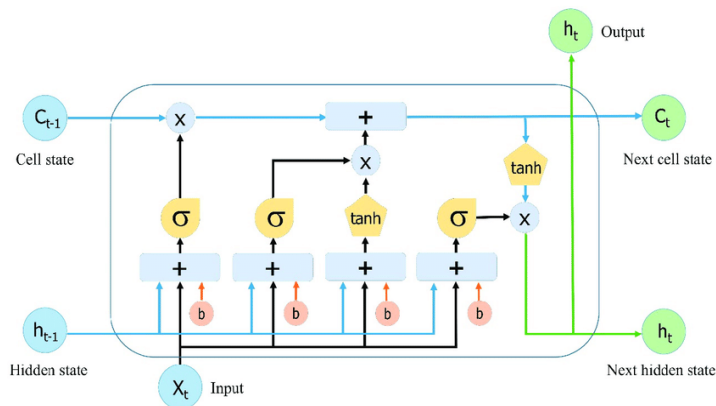
Karena LSTM memiliki lapisan-lapisan seperti lapisan input (input layer), lapisan tersembunyi (hidden layer), dan lapisan output (output layer). Kemudian LSTM juga memiliki 3 gerbang serta *memory cell* yang dapat melupakan atau menghafal informasi untuk menentukan berapa banyak informasi yang harus ditransfer ke sel berikutnya. Oleh karena itu, LSTM sangat cocok untuk klasifikasi dan prediksi yang berhubungan dengan waktu (Tholib et al., 2023).

Dalam penelitian ini, algoritma *Long Short Term Memory* (LSTM) digunakan. Karena algoritma ini dianggap memiliki kemampuan untuk menyimpan data untuk waktu yang lama atau jangka panjang, dan memiliki struktur yang terdiri dari 3 lapisan yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Seperti yang digambarkan pada gambar 2.




Gambar 2. Struktur LSTM

Kemudian pada lapisan tersembunyi LSTM memiliki gerbang-gerbang yang mengelola memori pada setiap masuknya data. Berikut gerbang yang dimiliki pada LSTM yaitu *Forget Gate*, *Input Gate*, *Cell State* dan *Output Gate*. Dapat dilihat pada Gambar 3.



Gambar 3. Memori LSTM

Berdasarkan gambar diatas *Long Short Term Memory* (LSTM) melakukan proses pertama data masuk kedalam proses *forget gate* merupakan proses mengidentifikasi informasi dengan menggunakan lapisan *sigmoid*. Proses yang dilakukan pada h_{t-1} dan x_t sehingga menghasilkan informasi yang tidak relevan akan dibuang serta informasi yang relevan akan disimpan dan diteruskan ke proses selanjutnya. *Forget gate* dapat dilihat pada gambar 4 dan persamaan 3.



Gambar 4. Forget Gate

$$f_t = \sigma (W_f \cdot X_t + W_f \cdot h_{t-1} + b_f) \quad (3)$$

keterangan :

f_t = Forget gate

σ = Sigmoid


W_f = Nilai weight

x_t = Nilai input pada orde ke t

h_{t-1} = Nilai output sebelum orde ke t

b_f = Nilai bias

Selanjutnya, data masuk ke proses *input gate* dengan menggunakan fungsi pada lapisan *sigmoid* yang bertujuan untuk penyaringan nilai dan penambahan informasi yang akan diteruskan ke proses berikutnya, *input gate* dapat dilihat pada gambar 5 dan persamaan 4.



Gambar 5. Input Gate

$$I_t = \sigma (W_i \cdot X_t + W_i \cdot h_{t-1} + b_i) \quad (4)$$

Keterangan :

I_t = Input gate

σ = Sigmoid

W_i = Nilai weight input gate

x_t = Nilai input pada orde ke t

h_{t-1} = Nilai output sebelum orde ke t

b_i = Nilai bias input gate

Selanjutnya, dengan menggunakan *layer tanh* untuk menghasilkan nilai konteks \hat{C}_t yang akan diperbarui pada proses *cell state*. Sehingga mendapatkan informasi yang diperlukan, dapat dilihat pada persamaan 5.

$$\hat{C}_t = \tanh (W_c \cdot X_t + W_c \cdot h_{t-1} + b_c) \quad (5)$$

Keterangan :

\hat{C}_t = Nilai baru yang ditambahkan pada cell state


Tanh = Fungsi tanh

W_c = Nilai weight cell state

x_t = Nilai input pada orde ke t

h_{t-1} = Nilai output sebelum orde ke t
 bc = Nilai bias cell state

Selanjutnya, proses *cell state* untuk melakukan update nilai menjadi nilai C_{t-1} (cell state baru), *cell state* dapat dilihat pada gambar 6 dan persamaan 6.



Gambar 6. Cell State

$$C_t = f_t * C_{t-1} + I_t * \hat{C}_t \quad (6)$$

Keterangan :

C_t = Cell state


f_t = Forget gate

C_{t-1} = Cell state sebelum orde ke t

I_t = Input gate

\hat{C}_t = Nilai baru yang ditambahkan pada cell state

Terakhir, data akan menuju *output gate*, merupakan tahapan terakhir untuk menghasilkan informasi yang relevan dari *cell state* sebagai nilai keluaran yang akan disajikan. Kemudian menuju *hidden state* yaitu dikalikannya nilai dengan *cell state* yang telah melalui lapisan *tanh*, dan mendapatkan nilai *hidden state* sebagai nilai keluaran yang akan digunakan input ke sel atau proses selanjutnya. *output gate* dapat dilihat pada gambar 7 dan persamaan 7, 8.



Gambar 7. Output Gate

$$O_t = \sigma (W_o \cdot x_t + W_o \cdot h_{t-1} + b_o) \quad (7)$$

Keterangan:

O_t = Output gate

σ = Sigmoid

W_o = Nilai weight output gate

x_t = Nilai input pada orde ke t

h_{t-1} = Nilai output sebelum orde ke t

b_o = Nilai bias output gate

$$H_t = O_t * \text{Tanh} (C_t) \quad (8)$$

Keterangan:

H_t = Hidden state

O_t = Nilai output

$\text{Tanh} (C_t)$ = Nilai cell state

2.1.9 RMSE dan MAPE

Root Mean Squared Error (RMSE) adalah ukuran yang diambil dengan menghitung perbedaan prediksi model sebagai nilai perkiraan yang akan diamati. Keakuratan nilai pada model RMSE apabila nilai prediksi yang didapatkan semakin kecil maka hasil kesalahan diperoleh akan akurat (Adi & Sudioanto, 2022).

Root Mean Squared Error (RMSE) merupakan uji validasi untuk mengukur ketepatan keputusan, sebagai parameter yang akan digunakan untuk membandingkan persamaan hasil prediksi dengan data asal. Perhitungan pada RMSE dimana nilai aktual dikurangi dengan nilai prediksi kemudian dikuadratkan selanjutnya dijumlahkan nilai keseluruhan dan dibagi dengan jumlah banyak data. Adapun perhitunga pada RMSE dapat dilihat pada persamaan 9.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (A_t - F_t)^2}{N}} \quad (9)$$

Keterangan :

A_t = Nilai aktual

F_t = Nilai perkiraan / prediksi

N = Banyaknya data

Mean Absolute Percentage Error (MAPE) merupakan alat ukur untuk menghitung tingkat error pada model data yang telah diolah, dalam melakukan prediksi atau peramalan. Dimana nilai pada MAPE semakin kecil makan model yang dibuat sangat baik dapat dilihat pada tabel 2, adapun rumus perhitungan MAPE dapat dilihat pada persamaan 10.

$$\text{MAPE} = \sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right| \times 100\% \quad (10)$$

Keterangan :

A_t = Nilai aktual

F_t = Nilai perkiraan / prediksi

N = Banyaknya data

Tabel 2. Nilai MAPE

<10%	Sangat Baik
10-20%	Baik
20-50%	Wajar
>50%	Tidak Baik

Sumber: Simatupang et al., 2022

2.2 Penelitian Terdahulu

- Judul** : Support Vector Regression (SVR) Dalam Memprediksi Harga Minyak Kelapa Sawit di Indonesia dan Nilai Tukar Mata Uang EUR/USD

Penelitian : Siti Saadah. (2021).

Isi : Pada penelitian ini bertujuan memprediksi harga minyak kelapa sawit di Indonesia dan nilai tukar mata uang EUR/USD dengan menggunakan *Support Vector Regression (SVR)*. Menyimpulkan hasil prediksi nilai tukar EUR/USD dengan menggunakan kernel RBF dapat memberikan tingkat akurasi paling tinggi yaitu nilai MSE sebesar 0.022 atau tingkat akurasinya mencapai 99,97%. Sedangkan pada minyak kelapa sawit dengan beberapa kali percobaan, dimana percobaan dengan nilai C (konstanta) sebesar 1000 dan nilai beta (bias) sebesar 0,0001. SVR mampu menghasilkan nilai MAPE sebesar 4,022 dan nilai R^2 sebesar 98,83%.
- Judul** : Klasifikasi Investasi Pada Resiko Investasi Minyak Kelapa Sawit Menggunakan Algoritma Naïve Bayes.

Penelitian : Yoga Religia dan Nunu Nurhasanah. (2019).

Isi : Pada penelitian memprediksi harga minyak kelapa sawit untuk resiko berinvestasi dengan menggunakan algoritma *Naive Bayes*. Dapat disimpulkan bahwa algoritma *Naive Bayes*, akurat untuk memprediksi harga minyak kelapa sawit. Dari hasil yang diperoleh nilai *Accuracy* 92,00%, *Recall* 95,83%, dan *Precision* 88,46%.
- Judul** : Oprimasi Fuzzy Artificial Neural Network Dengan Algoritma Genetika untuk Prediksi Harga Crude Palm Oil

Penelitian : Anwar Rifa'i. (2020).

Isi : Pada penelitian memprediksi harga *crude palm oil* dengan menggunakan *Fuzzy Radial Basis Fuction Neural Network (FRBFNN)* dan algoritma genetika. Menyimpulkan FRBFNN dapat memprediksi harga *crude palm oil* dengan tingkat error (MAPE) sebesar 11,7% pada data training dan 9,4% pada data testing, kemudian FRBFNN setelah di optimasi menggunakan algoritma genetika hasil prediksi mengalami peningkatan dengan hasil error (MAPE) menjadi 10,2% pada data training dan 8,3% pada data testing.
- Judul** : Prediksi Harga Minyak Goreng Curah dan Kemasan

Menggunakan Algoritma *Long Short Term Memory* (LSTM)

- Penelitian : Lailan Sahrina Hasibuan dan Yanda Novialdi. (2022).
- Isi : Pada penelitian memprediksi harga minyak goreng curah dan minyak goreng kemasan dengan menggunakan *Long Short Term Memory* (LSTM). Menyimpulkan bahwa LSTM dapat optimal untuk memprediksi harga minyak goreng curah dan kemasan dengan hasil RMSE yang didapatkan nilai sebesar 0,019 pada minyak goreng curah dan 0,039 pada minyak goreng kemasan.
5. Judul : Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long Short Term Memory)
- Penelitian : Adhitio Satyo Bayangkari Karno.(2020).
- Isi : Pada penelitian memprediksi data time series saham bank BRI dengan menggunakan *Long Short Term Memory* (LSTM). Dengan mengukur tingkat kesalahan menggunakan RMSE, dan memperoleh hasil yang cukup baik pada RMSE sebesar 227,47. Dengan visual grafik pada data prediksi serupa dengan grafik pada data aktual.

2.3 Tabel Perbandingan Penelitian

Perbandingan penelitian terdahulu sebagai berikut:


Tabel 3. Penelitian Terdahulu

Penelitian dan tahun	Metode				Visualiasi Grafik	Kriteria	Tingkat akurasi
	SVR	Naïve Bayes	ANN	LSTM			
Saadah, S. (2021).	√				√	Minyak kelapa sawit dan nilai tukar uang EUR/USD	MAPE 4,022 dan MSE 0,022
Religia & Nurhasanah. (2019).		√			√	Minyak kelapa sawit	Accuracy 92%
Rifa`i. (2020).			√		√	Crude Palm Oil	MAPE 8,3%
Hasibuan & Novialdi. (2022).				√	√	Minyak goreng curah & kemasan	RMSE 0,019 dan 0,039
Karno, A. S. B. (2020).				√	√	Saham bank BRI	RMSE 227,47
Saputra, M. F. (2023)				√	√	Minyak kelapa sawit internasional	MAPE 2,70%; 3,18% dan 1,90%

BAB III METODOLOGI PENELITIAN

3.1 Metode Penelitian

Metode yang dilakukan dalam penelitian ini adalah menggunakan data mining yang disebut dengan CRISP-DM (Cross Industry Standart Process For Data Mining). CRISP-DM mempunyai struktur yang dapat menyelesaikan masalah baik penelitian ataupun bisnis dengan 6 tahapan meliputi *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* (Huber et al., 2019). Tahapan CRISP-DM yang terdiri dari 6 tahapan ditunjukkan pada gambar 8.



Gambar 8. Tahapan CRISP-DM

3.1.1 Business Understanding

Tahapan *business understanding* merupakan tahapan yang berfokus pada tujuan dari masalah apa yang terjadi yang menghasilkan hasil yang baik, serta tujuan dengan persyaratan pada tahapan *Business Understanding*.

3.1.2 Data Understanding

Tahapan *data understanding* merupakan tahapan untuk mengetahui sumber data serta model yang akan digunakan. dengan tujuan yang berfokus pada mengidentifikasi, mengumpulkan dan menganalisis untuk membantu mencapai tujuan output yang dihasilkan.

3.1.3 Data Preparation

Tahapan *data preparation* merupakan tahapan pengambilan data *library* yang disediakan oleh python yang digunakan untuk proses memprediksi harga minyak kelapa sawit atau *Crude Palm Oil (CPO)*, selanjutnya mengubah mengubah tipe data pada dataset, serta pengecekan kolom yang memiliki nilai null. Kemudian pada tahapan ini juga dilakukan proses *transformation* data, yaitu melakukan normalisasi data menjadi range 0 – 1 menggunakan metode *min – max scaling*. Dan sebelum melanjutkan ke tahap *modelling*, dataset dibagi menjadi data training dan data uji.

3.1.4 Modelling

Tahapan *modelling* merupakan tahapan proses pengujian data dengan menggunakan model yang terpilih. Model pendekatan pada penelitian ini, ialah model *Long Short Term Memory* (LSTM). Dengan proses yang dimiliki oleh LSTM meliputi *forget gate*, *Input gate*, *Cell state*, dan *Output gate*.

3.1.5 Evaluation

Tahapan *evaluation* merupakan tahapan mengetahui hasil prediksi yang telah melalui tahapan *modelling*, apakah model memenuhi kriteria keberhasilan. Untuk menentukan data akan melanjutkan ke proses selanjutnya, atau melakukan tahapan awal untuk mendapatkan hasil yang maksimal.

3.1.6 Deployment

Tahapan *deployment* merupakan tahapan akhir dari CRISP-DM, data yang telah selesai proses dan mendapatkan hasil yang optimal akan divisualisasikan supaya lebih mudah untuk dipahami oleh pengguna. Sehingga orang yang berkepentingan dapat memprediksi yang akan terjadi pada model yang telah diperoleh, dan visualisasi biasanya disajikan dalam bentuk grafis.

3.2 Waktu dan Tempat Penelitian

Waktu penelitian dilakukan mulai dari bulan Oktober 2022 sampai February 2023. Dan penelitian dilaksanakan di Laboratorium Komputer Program Studi Ilmu Komputer FMIPA universitas Pakuan Bogor yang beralamat di Jl. Pakuan, RT.02/RW.06, Tegallea, Kecamatan Bogor Tengah, Kota Bogor, Jawa Barat 16129.

3.3 Alat dan Bahan

3.3.1 Alat

Adapun dalam penelitian alat yang dibutuhkan ialah *hardware* dan *software* yang meliputi :

A. Hardware :

1. Laptop
2. ROM 512GB SSD & RAM 8GB

B. Software :

1. Sistem operasi windows 10
2. Microsoft word 2019
3. Microsoft excel 2019
4. Google chrome
5. Google Colaboratory

3.3.2 Bahan

Bahan-bahan yang digunakan pada penelitian meliputi :

- a. Data historis Palm Oil AS Futures pada website id.investing.com.
- b. Jurnal-jurnal penelitian terdahulu serta media internet sebagai penunjang bahan penelitian.

BAB IV PERANCANGAN DAN IMPLEMENTASI

4.1 Perancangan Sistem

4.1.1 Business Understanding

Pada tahap *business understanding*, tujuannya adalah untuk merumuskan masalah yang terjadi dan strategi bagaimana untuk mencapai tujuan yang diinginkan. Tujuan dari penelitian ini adalah untuk membuat model arsitektur yang menggunakan algoritma deep learning *Long Short Term Memory* (LSTM) untuk memprediksi harga minyak kelapa sawit (CPO). Beberapa pengujian dilakukan pada pemodelan LSTM untuk mencapai prediksi harga yang optimal dengan nilai *epoch* yang berbeda.

4.1.2 Data Understanding

Pada tahap data *understanding*, yaitu dataset yang akan digunakan untuk melakukan proses pemodelan dikumpulkan. Adapun data yang digunakan dalam penelitian ini adalah data *time series* mingguan *palm oil* dari Januari 2017 hingga Desember 2022, seperti yang ditunjukkan pada lampiran 1. Setelah itu sebagian variabel akan di hapus seperti yang ditunjukkan pada gambar 9, dan selanjutnya ada 3 variabel yang akan digunakan pada penelitian meliputi *price*, *high*, dan *low* dapat dilihat pada tabel 4.

```
[ ] #Mengdrop variabel yang tidak digunakan
df.drop(["Open", "Vol.", "Change %"], axis=1, inplace=True)
```

Gambar 9. Menghapus variabel

Tabel 4. Variabel Yang Digunakan

Date	Price	High	Low
01/01/2017	3,200.00	3,250.00	3,153.00
08/01/2017	3,280.00	3,330.00	3,170.00
15/01/2017	3,234.00	3,268.00	3,185.00
22/01/2017	3,243.00	3,320.00	3,216.00
29/01/2017	3,250.00	3,267.00	3,205.00
...
27/11/2022	3,905.00	4,174.00	3,900.00
04/12/2022	3,924.00	4,040.00	3,820.00
11/12/2022	3,863.00	3,950.00	3,680.00
18/12/2022	3,802.00	3,939.00	3,791.00
25/12/2022	4,171.00	4,225.00	3,950.00

4.1.3 Data Preparation

Data *preparation* tahapan memanggil *library-library* yang telah disediakan oleh *python*, *library* ini akan digunakan untuk menjalankan program untuk melakukan prediksi harga minyak kelapa sawit dengan LSTM. *Source code* pemanggilan *library* dapat dilihat pada gambar 10.

```

▶ #Import library yang akan digunakan
import math
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from datetime import datetime
from google.colab import drive
plt.style.use('bmh')

#Import library untuk normalisasi dan model LSTM
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM, Dropout

```

Gambar 10. Pemanggilan library python

Library Python yang akan digunakan dalam penelitian ini ditunjukkan dalam Gambar 8, seperti math (melakukan operasi matematika), pandas (untuk membaca format file), numpy (melakukan komputasi numerik seperti array & matriks), matplotlib (membuat visualisasi grafik), datetime (pemrosesan data berdasarkan tanggal & waktu), drive (menghubungkan colaboratory dengan google drive). Selanjutnya ada library yang digunakan untuk pemodelan seperti minmaxscaler (untuk normalisasi data) dan dense, lstm, dropout (untuk membuat model LSTM).

Selanjutnya pada tahap data *preparation* yaitu mengubah tipe data pada variabel, yaitu tipe data *object* diubah menjadi tipe data *float*. Ini dilakukan untuk mengurangi kemungkinan error pada data, dapat dilihat pada gambar 11.

```

[ ] #tipe data sebelum diubah
df.dtypes

Price    object
High     object
Low      object
dtype: object

[ ] #Mengubah typedata variabel dari object menjadi float
df["Price"] = df['Price'].str.replace(',', '').astype(float)

df["High"] = df['High'].str.replace(',', '').astype(float)

df["Low"] = df['Low'].str.replace(',', '').astype(float)

[ ] #tipe data sesudah diubah
df.dtypes

Price    float64
High     float64
Low      float64
dtype: object

```

Gambar 11. Mengubah tipe data

Kemudian, membagi dataset menjadi 2 data yaitu 80% data training (251 data) dan 20% data uji (62 data). Berikut source code pembagian dataset dapat dilihat pada gambar 12.

```

▶ #Membagi data menjadi data train sebesar 80% dan test 20%
train_size = math.ceil(len(dataset_new) * 0.8)

test_size = math.ceil(len(dataset_new) - train_size)

print('Jumlah data train : ', train_size)
print('Jumlah data test : ', test_size)

👉 Jumlah data train : 251
   Jumlah data test : 62

```

Gambar 12. Pembagian Data Training Dan Test

Kemudian, agar dataset dapat diproses pada tahap pemodelan dengan *Long Short Term Memory* (LSTM), dilakukan pada tahap *transformation* yaitu melakukan normalisasi data menjadi nilai dengan skala range 0 - 1 menggunakan *min-max scaling* yang dapat dilihat pada **persamaan 1**. Berikut perhitungan secara manual normalisasi pada 20 data sampel variabel *price*, *high*, dan *low* yaitu dari tanggal 14-08-2022 hingga 25-12-2022 dengan menggunakan *min-max scaling* dapat dilihat pada tabel 5,6,7.

1. Normalisasi data sampel *price*

Nilai tertinggi: 4.187

Nilai terendah: 3.327

$$X_1 = \frac{(X_1 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.090 - 3.327)}{(4.187 - 3.327)} = \frac{763}{860} = 0,9136$$

$$X_2 = \frac{(X_2 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.149 - 3.327)}{(4.187 - 3.327)} = \frac{822}{860} = 0,9558$$

Tabel 5. Normalisasi Data Sampel Variabel Price

Normalisasi Data Sampel Price		
0,5849	0,3756	0,8523
0,2012	0,7581	0,6721
0,4337	0,5802	0,6942
0,4023	0,9942	0,6233
0	1	0,5523
0,3523	0,5395	0,9814

2. Normalisasi data sampel *high*

Nilai tertinggi: 4.330

Nilai terendah: 3.566

$$X_1 = \frac{(X_1 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.264 - 3.566)}{(4.330 - 3.566)} = \frac{698}{764} = 0,9136$$

$$X_2 = \frac{(X_2 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.330 - 3.566)}{(4.330 - 3.566)} = \frac{764}{764} = 1$$

Tabel 6. Normalisasi Data Sampel Variabel High

Normalisasi Data Sampel High		
0,8037	0,1099	0,7055
0,3835	0,6688	0,7958
0,2408	0,6924	0,6204
0,3586	0,8691	0,5026
0	0,9215	0,4882
0,1099	0,5589	0,8626

3. Normalisasi data sampel *low*

Nilai tertinggi: 4.092

Nilai terendah: 3.143

$$X_1 = \frac{(X_1 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.049 - 3.143)}{(4.092 - 3.143)} = \frac{906}{949} = 0,9547$$

$$X_2 = \frac{(X_1 - X_{min})}{(X_{max} - X_{min})} = \frac{(4.092 - 3.143)}{(4.092 - 3.143)} = \frac{949}{949} = 1$$

Tabel 7. Normalisasi Data Sampel Variabel Low

Normalisasi Data Sampel Low		
0,6849	0,3846	0,6396
0,3235	0,5785	0,7977
0,4078	0,6396	0,7134
0,4394	0,6870	0,5659
0	0,9241	0,6828
0,1654	0,6354	0,8504

4.1.4 Modelling

Tahap modelling merupakan tahapan perhitungan pada dataset dengan menggunakan model pendekatan *Long Short Term Memory* (LSTM), setelah proses normalisasi pada dataset. Hal pertama ialah menentukan nilai bobot yang akan digunakan untuk perhitungan.

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

$$W = \left(-\frac{1}{\sqrt{20}}, \frac{1}{\sqrt{20}} \right)$$

$$W = (-0,223; 0,223)$$

Langkah pertama, pada *Long Short Term Memory* (LSTM) ialah menghitung pada *forget gate* untuk menentukan apakah nilai akan dibuang atau di simpan untuk dilanjutkan ke proses berikutnya, menggunakan persamaan 3. Perhitungan 20 data sampel *forget gate* dapat dilihat pada tabel 8.

Diketahui :

$$h_{t-1} = 0$$

$$C_{t-1} = 0$$

$$\text{Weight} = 0,223$$

Bias forget gate, input gate, C_t , dan output gate ialah 0,4; 0,2; 0,3; 0,1

Tabel 8. Forget Gate

Variabel	Forget Gate
<i>Price</i>	$f_t = \sigma (W_f \cdot X_t + W_f \cdot h_{t-1} + b_f)$ $f_t = \sigma (0,223 * 0,8872 + 0,223 * 0 + 0,4)$ $f_t = \sigma (0,598)$ $f_t = 0,6453$
<i>High</i>	$f_t = \sigma (W_f \cdot X_t + W_f \cdot h_{t-1} + b_f)$ $f_t = \sigma (0,223 * 0,9136 + 0,223 * 0 + 0,4)$ $f_t = \sigma (0,604)$ $f_t = 0,6466$
<i>Low</i>	$f_t = \sigma (W_f \cdot X_t + W_f \cdot h_{t-1} + b_f)$ $f_t = \sigma (0,223 * 0,9547 + 0,223 * 0 + 0,4)$ $f_t = \sigma (0,613)$ $f_t = 0,6487$

Langkah ke dua menghitung *input gate* untuk mendapatkan atau menentukan kandidat baru untuk proses selanjutnya di *cell state* menggunakan persamaan 4 dan 5. Perhitungan *input gate* dapat dilihat pada tabel 9.

Tabel 9. Input Gate

Variabel	Input Gate
<i>Price</i>	$I_t = \sigma (W_i \cdot x_t + W_i \cdot h_{t-1} + b_i)$ $I_t = \sigma (0,223 * 0,8872 + 0,223 * 0 + 0,2)$ $I_t = \sigma (0,398)$ $I_t = 0,5983 \quad \hat{C}_t = \tanh (W_c \cdot x_t + W_c \cdot h_{t-1} + b_c)$
	$\hat{C}_t = \tanh (0,223 * 0,8872 + 0,223 * 0 + 0,3)$ $\hat{C}_t = \tanh (0,498)$ $\hat{C}_t = 0,4608$
<i>High</i>	$I_t = \sigma (W_i \cdot x_t + W_i \cdot h_{t-1} + b_i)$ $I_t = \sigma (0,223 * 0,9136 + 0,223 * 0 + 0,2)$ $I_t = \sigma (0,404)$ $I_t = 0,5997$
<i>High</i>	$\hat{C}_t = \tanh (W_c \cdot x_t + W_c \cdot h_{t-1} + b_c)$ $\hat{C}_t = \tanh (0,223 * 0,9136 + 0,223 * 0 + 0,3)$ $\hat{C}_t = \tanh (0,504)$ $\hat{C}_t = 0,4655$

Variabel	Input Gate
Low	$I_t = \sigma (W_i.x_t + W_i.ht_{-1} + b_i)$ $I_t = \sigma (0,223 * 0,9547 + 0,223 * 0 + 0,2)$ $I_t = \sigma (0,413)$ $I_t = 0,6019$
	$\hat{C}_t = \tanh (W_c.x_t + W_c.ht_{-1} + b_c)$ $\hat{C}_t = \tanh (0,223 * 0,9547 + 0,223 * 0 + 0,3)$ $\hat{C}_t = \tanh (0,513)$ $\hat{C}_t = 0,4726$

Langkah ketiga ialah mengupdate nilai *cell state* yang sebelumnya, menjadi nilai *cell state* baru menggunakan persamaan 6. Perhitungan *cell state* dapat dilihat pada tabel 10.

Tabel 10. Cell State

Variabel	Cell State
Price	$C_t = f_t * C_{t-1} + i_t * \hat{C}_t$ $C_t = 0,6453 * 0 + 0,5983 * 0,4608$ $C_t = 0,2757$
High	$C_t = f_t * C_{t-1} + i_t * \hat{C}_t$ $C_t = 0,6466 * 0 + 0,5997 * 0,4655$ $C_t = 0,2792$
Low	$C_t = f_t * C_{t-1} + i_t * \hat{C}_t$ $C_t = 0,6487 * 0 + 0,6019 * 0,4726$ $C_t = 0,2845$

Langkah terakhir ialah menghitung *output gate* dengan menggunakan persamaan 7, selanjutnya menghitung *hidden state* dengan persamaan 8. *Hidden state* akan digunakan untuk perhitungan hari selanjutnya. Perhitungan *output gate* dan *hidden state* dapat dilihat pada tabel 11.

Tabel 11. Output Gate dan Hidden State

Variabel	Output Gate dan Hidden State
Price	$O_t = \sigma (W_o.x_t + W_o.ht_{-1} + b_o)$ $O_t = \sigma (0,223 * 0,8872 + 0,223 * 0 + 0,1)$ $O_t = \sigma (0,298)$ $O_t = 0,5740$
	$h_t = o_t * \tanh (C_t)$ $h_t = 0,5740 * 0,2689$ $h_t = 0,1544$
High	$O_t = \sigma (W_o.x_t + W_o.ht_{-1} + b_o)$ $O_t = \sigma (0,223 * 0,9136 + 0,223 * 0 + 0,1)$ $O_t = \sigma (0,304)$ $O_t = 0,5755$

Variabel	Output Gate dan Hidden State
	$h_t = o t * t a n h (C t)$ $h_t = 0,5755 * 0,4578$ $h_t = 0,1566$
<i>Low</i>	$O_t = \sigma (W_t.x_t + W_i.ht-1 + b_t)$ $O_t = \sigma (0,223 * 0,9547 + 0,223 * 0 + 0,1)$ $O_t = \sigma (0,313)$ $O_t = 0,5777$
	$h_t = o t * t a n h (C t)$ $h_t = 0,5777 * 0,2771$ $h_t = 0,1601$

Adapun, perhitungan manual selanjutnya hingga tanggal 18 desember 2022 dengan nilai *hidden state* yang digunakan untuk proses selanjutnya. Dapat dilihat pada tabel 12.

Tabel 12. Output Hidden State

H_t (Price)		H_t (High)		H_t (Low)	
0,2642	0,4116	0,2695	0,3932	0,2715	0,3794
0,3003	0,4338	0,3234	0,4170	0,3137	0,4114
0,2930	0,4079	0,3221	0,3996	0,3118	0,4027
0,3157	0,4275	0,3147	0,4082	0,3242	0,4028
0,3248	0,4188	0,3232	0,4195	0,3345	0,4172
0,2939	0,4185	0,2936	0,4097	0,3000	0,4164
0,3121	0,4115	0,2892	0,3959	0,2989	0,4044
0,3213	0,4017	0,2846	0,3874	0,3160	0,4096
0,3625	0,4345	0,3334	0,4155	0,3423	0,4257
0,3676		0,3599		0,3625	

Selanjutnya, data di denormalisasi untuk lanjut ke proses evaluasi dengan RMSE untuk mengukur tingkat kesalahan dan MAPE untuk mengukur tingkat error. Dengan membandingkan data nilai aktual dan nilai prediksi, dapat dilihat pada persamaan 2 dan tabel 13.

$$\begin{aligned}
 \text{Price} &= X_t = 0,1544 (4187 - 3327) + 3327 \\
 &X_t = 0,1544 * 860 + 3327 \\
 &X_t = 3460
 \end{aligned}$$

$$\begin{aligned}
 \text{High} &= X_t = 0,1566 (4330 - 3566) + 3566 \\
 &X_t = 0,1566 * 764 + 3566 \\
 &X_t = 3686
 \end{aligned}$$

$$\begin{aligned}
Low &= X_t = 0,1601 (4092 - 3143) + 3143 \\
&X_t = 0,1601 * 949 + 3143 \\
&X_t = 3295
\end{aligned}$$

Tabel 13. Denormalisasi Data

Denormalisasi (Price)		Denormalisasi (High)		Denormalisasi (Low)	
3554	3681	3772	3866	3401	3503
3585	3700	3813	3885	3441	3533
3579	3678	3812	3871	3439	3525
3598	3695	3806	3878	3451	3525
3606	3687	3813	3886	3460	3539
3580	3687	3790	3879	3428	3538
3595	3681	3787	3868	3427	3527
3603	3672	3783	3862	3443	3532
3639	3701	3821	3883	3468	3547
3643		3841		3487	

4.1.5 Evaluation

Tahap *evaluation* merupakan tahapan evaluasi data yang telah melalui proses pemodelan LSTM, dengan mengukur tingkat kesalahan pada model menggunakan *Root Mean Square Error* (RMSE) dan untuk tingkat keakurasian model menggunakan *Mean Absolute Percatege Error* (MAPE). Berikut hasil evaluasi pada 20 data sampel *price*, *high*, *low* yang telah melalui proses pemodelan, selanjutnya pengujian tingkat kesalahan dengan RMSE dan tingkat keakurasian dengan MAPE untuk mengetahui hasil prediksi pada dataset.

1. Perhitungan RMSE Price

Rumus RMSE dapat dilihat pada persamaan 9

$$\begin{aligned}
&= \sqrt{\frac{(4090 - 3460)^2 + (4149 - 3554)^2 + (3830 - 3585)^2 + (3500 - 3579)^2 + (3700 - 3598)^2 +}{20}} \\
&= \sqrt{\frac{(3673 - 3606)^2 + (3327 - 3580)^2 + (3630 - 3595)^2 + (3650 - 3603)^2 + (3979 - 3639)^2 +}{20}} \\
&= \sqrt{\frac{(3826 - 3643)^2 + (4182 - 3681)^2 + (4187 - 3700)^2 + (3791 - 3678)^2 + (4060 - 3695)^2 +}{20}} \\
&= \sqrt{\frac{(3905 - 3687)^2 + (3924 - 3687)^2 + (3863 - 3681)^2 + (3802 - 3671)^2 + (4171 - 3701)^2 +}{20}} \\
&= \sqrt{\frac{2057658}{20}} = \sqrt{102882,9} = 320,75
\end{aligned}$$

2. Perhitungan MAPE Price

Rumus MAPE dapat dilihat pada persamaan 10

$$\begin{aligned}
 &= \sqrt{\frac{\left(\frac{4090-3460}{4090}\right) + \left(\frac{4149-3554}{4149}\right) + \left(\frac{3830-3585}{3830}\right) + \left(\frac{3500-3579}{3500}\right) + \left(\frac{3700-3598}{3700}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{3673-3606}{3673}\right) + \left(\frac{3327-3580}{3327}\right) + \left(\frac{3630-3595}{3630}\right) + \left(\frac{3650-3603}{3650}\right) + \left(\frac{3979-3639}{3979}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{3826-3643}{3826}\right) + \left(\frac{4182-3681}{4182}\right) + \left(\frac{4187-3700}{4187}\right) + \left(\frac{3791-3678}{3791}\right) + \left(\frac{4060-3695}{4060}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{3905-3687}{3905}\right) + \left(\frac{3924-3687}{3924}\right) + \left(\frac{3863-3681}{3863}\right) + \left(\frac{3802-3671}{3802}\right) + \left(\frac{4171-3701}{4171}\right)}{20}} \\
 &= \frac{1,327}{20} \times 100\% = 0,0663 \times 100\% = 6,63\%
 \end{aligned}$$

Nilai evaluasi pada data sampel *price* yaitu untuk nilai RMSE sebesar 320,75 dan nilai MAPE sebesar 6,63%.

3. Perhitungan RMSE High

Rumus RMSE dapat dilihat pada persamaan 9

$$\begin{aligned}
 &= \sqrt{\frac{(4264 - 3686)^2 + (4330 - 3772)^2 + (4180 - 3813)^2 + (3859 - 3812)^2 + (3750 - 3806)^2}{20}} \\
 &= \sqrt{\frac{(3840 - 3813)^2 + (3566 - 3790)^2 + (3650 - 3787)^2 + (3650 - 3783)^2 + (4077 - 3821)^2}{20}} \\
 &= \sqrt{\frac{(4095 - 3841)^2 + (4230 - 3866)^2 + (4270 - 3885)^2 + (3993 - 3871)^2 + (4105 - 3878)^2}{20}} \\
 &= \sqrt{\frac{(4174 - 3886)^2 + (4040 - 3879)^2 + (3950 - 3868)^2 + (3939 - 3862)^2 + (4225 - 3883)^2}{20}} \\
 &= \sqrt{\frac{1588513}{20}} = \sqrt{79425,65} = 281,82
 \end{aligned}$$

4. Perhitungan MAPE High

Rumus MAPE dapat dilihat pada persamaan 10

$$\begin{aligned}
 &= \sqrt{\frac{\left(\frac{4264-3686}{4264}\right) + \left(\frac{4330-3772}{4330}\right) + \left(\frac{4180-3813}{4180}\right) + \left(\frac{3859-3812}{3859}\right) + \left(\frac{3750-3806}{3750}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{3840-3813}{3840}\right) + \left(\frac{3566-3790}{3566}\right) + \left(\frac{3650-3787}{3650}\right) + \left(\frac{3650-3783}{3650}\right) + \left(\frac{4077-3821}{4077}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{4095-3841}{4095}\right) + \left(\frac{4230-3866}{4230}\right) + \left(\frac{4270-3885}{4270}\right) + \left(\frac{3993-3871}{3993}\right) + \left(\frac{4105-3878}{4105}\right)}{20}} \\
 &= \sqrt{\frac{\left(\frac{4174-3886}{4174}\right) + \left(\frac{4040-3879}{4040}\right) + \left(\frac{3950-3868}{3950}\right) + \left(\frac{3939-3862}{3939}\right) + \left(\frac{4225-3883}{4225}\right)}{20}} \\
 &= \frac{1,1393}{20} \times 100\% = 0,0569 \times 100\% = 5,69\%
 \end{aligned}$$

Nilai evaluasi pada data sampel High yaitu untuk nilai RMSE sebesar 281,82 dan nilai MAPE sebesar 5,69%.

5. Perhitungan RMSE Low

Rumus RMSE dapat dilihat pada persamaan 9

$$\begin{aligned}
 &= \sqrt{\frac{(4049 - 3295)^2 + (4092 - 3401)^2 + (3793 - 3441)^2 + (3450 - 3439)^2 + (3530 - 3451)^2 +}{20}} \\
 &= \sqrt{\frac{(3560 - 3460)^2 + (3143 - 3428)^2 + (3300 - 3427)^2 + (3508 - 3443)^2 + (3692 - 3468)^2 +}{20}} \\
 &= \sqrt{\frac{(3750 - 3487)^2 + (3795 - 3503)^2 + (4020 - 3533)^2 + (3746 - 3525)^2 + (3750 - 3525)^2 +}{20}} \\
 &= \sqrt{\frac{(3900 - 3539)^2 + (3820 - 3538)^2 + (3680 - 3527)^2 + (3791 - 3532)^2 + (3950 - 3547)^2 +}{20}} \\
 &= \sqrt{\frac{2290350}{20}} = \sqrt{114517,5} = 338,40
 \end{aligned}$$

6. Perhitungan MAPE Low

Rumus MAPE dapat dilihat pada persamaan 10

$$\begin{aligned}
 &= \sqrt{\frac{\left(\frac{4049 - 3295}{4049}\right) + \left(\frac{4092 - 3401}{4092}\right) + \left(\frac{3793 - 3441}{3793}\right) + \left(\frac{3450 - 3439}{3450}\right) + \left(\frac{3530 - 3451}{3530}\right) +}{20}} \\
 &= \sqrt{\frac{\left(\frac{3560 - 3460}{3560}\right) + \left(\frac{3143 - 3428}{3143}\right) + \left(\frac{3300 - 3427}{3300}\right) + \left(\frac{3508 - 3443}{3508}\right) + \left(\frac{3692 - 3468}{3692}\right) +}{20}} \\
 &= \sqrt{\frac{\left(\frac{3750 - 3487}{3750}\right) + \left(\frac{3795 - 3503}{3795}\right) + \left(\frac{4020 - 3533}{4020}\right) + \left(\frac{3746 - 3525}{3746}\right) + \left(\frac{3750 - 3525}{3750}\right) +}{20}} \\
 &= \sqrt{\frac{\left(\frac{3900 - 3539}{3900}\right) + \left(\frac{3820 - 3538}{3820}\right) + \left(\frac{3680 - 3527}{3680}\right) + \left(\frac{3791 - 3532}{3791}\right) + \left(\frac{3950 - 3547}{3950}\right) +}{20}} \\
 &= \frac{1,4741}{20} \times 100\% = 0,0737 \times 100\% = 7,37\%
 \end{aligned}$$

Nilai evaluasi pada data sampel price yaitu untuk nilai RMSE sebesar 338,40 dan nilai MAPE sebesar 7,37%.

4.1.6 Deployment

Pada tahap ini, informasi terkait data akan disajikan. Data yang telah diproses akan divisualisasikan sehingga lebih mudah untuk dipahami oleh pengguna. Selain itu, pihak yang terlibat dapat mengantisipasi apa yang akan terjadi dari hasil prediksi yang didapatkan. Visualisasi biasanya ditunjukkan dalam bentuk grafik.

4.2 Implementasi

Tahap implementasi adalah tahapan pengembangan atau pembangunan dari sistem yang sudah dirancang, pada tahap ini Pembangunan model menggunakan bahasa *python* dengan *text editor google colab*. Selanjutnya beberapa *library python* digunakan seperti *math* digunakan pembagian data training dan uji, *numpy* untuk memproses array multidimensi, *pandas* untuk membaca file csv, *sklearn* digunakan untuk normalisasi data, *keras* untuk proses model LSTM, dan *matplotlib* untuk menunjukkan visualisasi grafik. Tahap implementasi dapat dilihat pada gambar 13.

```
#Import library yang akan digunakan
import math
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from datetime import datetime
from google.colab import drive
drive.mount('/gdrive/MyDrive')

#Import library untuk normalisasi dan model LSTM
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM, Dropout
```

```
#Membuka dataset dari Google drive
df = pd.read_csv("/content/drive/MyDrive/Data Minyak kepala Sawit/Palm Oil Futures Historical Data.csv")
df
```

	Date	Price	Open	High	Low	Vol.	Change %
0	12/25/2022	4,171.00	3,950.00	4,225.00	3,950.00	5.70K	9.71%
1	12/18/2022	3,802.00	3,904.00	3,939.00	3,791.00	7.02K	-1.58%
2	12/11/2022	3,863.00	3,780.00	3,950.00	3,680.00	2.02K	-1.55%
3	12/04/2022	3,924.00	3,890.00	4,040.00	3,820.00	0.35K	0.49%
4	11/27/2022	3,905.00	4,123.00	4,174.00	3,900.00	2.77K	-3.82%

Gambar 13. Implementasi Google Colaboratory

BAB V HASIL DAN PEMBAHASAN

5.1 Hasil

Tahapan perancangan serta implementasi yang telah dijelaskan sebelumnya untuk desain program. Berikut ini adalah hasil program yang dikembangkan serta pembahasan pada program.

5.1.1 Data Preparation

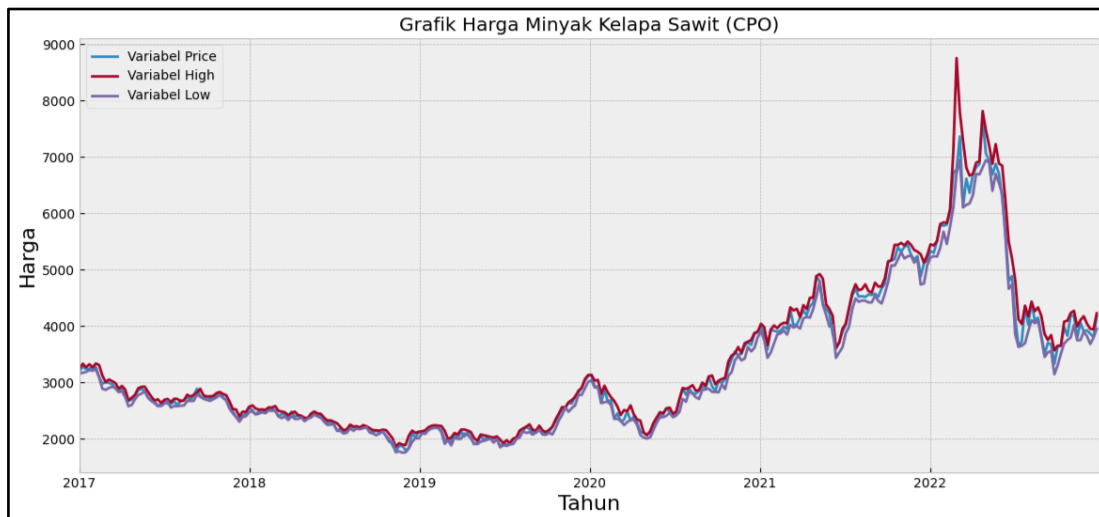
Pada tahap data preparation merupakan tahapan preprocessing yang terdiri dari pemilihan variabel penelitian, mengubah tipe data pada variabel, normalisasi, dan juga membagi dataset menjadi data training dan data uji dengan jumlah data digunakan sebanyak 313 data dengan periode mingguan dari bulan Januari 2017 sampai Desember 2022. Kemudian data dibagi menjadi data training sebesar 80% yaitu dari tanggal 01-01-2017 hingga 17-10-2021 dan data test sebesar 20% yaitu dari tanggal 24-10-2021 hingga 25-12-2022, yang dapat dilihat pada tabel 14.

Tabel 14. Pembagian Data Training dan Test

No.	Variabel	Jumlah data keseluruhan	Data Training 80%	Data Test 20%
1.	Price	313	251	62
2.	High	313	251	62
3.	Low	313	251	62

5.1.1.1 Seleksi Data

Proses tahapan ini ialah membaca dataset dari data mingguan harga minyak kelapa sawit sebanyak 313 data dari periode 1 Januari 2017 hingga 31 Desember 2022. Dengan 3 variabel yang akan di uji ialah variabel price, high, dan low. Dapat dilihat pada gambar 14.



Gambar 14. Visualisasi Variabel Penelitian

Gambar 14 menunjukkan pola - pola waktu harga minyak kelapa sawit (CPO) dari tahun 2017 hingga 2022. Pola harga dari 2017 hingga 2020 dapat dianggap stabil di antara 2000 dan 3000 ringgit, kemudian meningkat pada tahun 2021 dengan harga 5000 ringgit. Selanjutnya, pada awal tahun 2022 mengalami peningkatan yang sangat besar pada variabel high (harga tertinggi) menyentuh harga sebesar 8500 ringgit, tetapi kembali turun pada pertengahan tahun 2022 hingga menyentuh harga 3000 hingga 4000 ringgit.

5.1.1.2 Normalisasi

Tahapan ini ialah proses normalisa pada dataset yaitu melakukan skala data antara range 0 – 1 dengan menggunakan min – max scaler. Proses normalisasi dapat dilihat pada gambar 15 dan hasil normalisasi data dapat dilihat pada lampiran 2.

```
#Normalisasi dataset menjadi range 0-1 menggunakan min-max scaler
scaler = MinMaxScaler(feature_range=(0,1))
data_scaled = scaler.fit_transform(dataset_new)
```

Gambar 15. Proses Normalisasi

5.1.2 Modelling

Tahap modelling merupakan proses uji coba skenario penelitian berdasarkan jumlah parameter epoch yang berbeda untuk mendapatkan hasil yang optimal. Rancangan skenario parameter yang akan dibangun dapat dilihat pada tabel 15.

Tabel 15. Arsitektur dan Parameter

No	Nama	Jenis/Nilai
1.	Layer	LSTM
2.	Neuron hidden	50
3.	Optimizer	Adam
4.	Batch size	1
5.	Epoch	10,20,30,40,50,60,70 & 100, 150, 200, 250,300

5.1.3 Evaluation

Tahap ini, dilakukan evaluasi pada data setelah selesai dari tahap pemodelan LSTM dengan menggunakan *error* model RMSE (Root Mean Square Error) dan MAPE (Mean Absolute Percetange Error), berfungsi untuk mengidentifikasi kesalahan yang terjadi antara nilai prediksi dan nilai aktual dalam model prediksi.

5.2 Pembahasan

Berdasarkan Hasil program yang telah digunakan untuk memprediksi harga minyak kelapa sawit (CPO) divisualisasikan dalam bentuk grafik. Hasil pengujian digunakan dengan nilai epoch yang berbeda untuk menghasilkan prediksi harga yang akurat dan optimal.

5.2.1 Hasil Akurasi Penngujian Model

Dalam penelitian ini, skenario pengujian pemodelan dilakukan dengan nilai *epoch* yang berbeda. Selanjutnya, setiap pengujian menghasilkan tingkat *error* yang berbeda, sehingga grafik dengan tingkat *error* terkecil dari setiap skenario pengujian model digunakan untuk menentukan hasil yang paling tepat.

5.2.1.1 Hasil Pengujian Variabel Price

Pengujian pada variabel price dengan percobaan nilai epoch yang berbeda yaitu epoch 10 – 70 dan 100 – 300. Sehingga mendapatkan hasil yang optimal dapat dilihat pada tabel 16.

Tabel 16. Pengujian Variabel Price

Epoch	RMSE	MAPE
10	512,75	7,35%
20	471,94	6,92%
30	417,02	6,19%
40	433,55	6,53%
50	394,97	5,93%
60	384,14	5,75%
70	480,95	7,05%
...
100	422,56	6,21%
150	441,61	6,35%
200	667,85	9,19%
250	710,48	9,54%
300	978,83	12,68%

Tabel 16 menunjukkan hasil uji coba untuk dengan nilai epoch berbeda pada variabel price. Di mana epoch 60, memperoleh evaluasi RMSE dan MAPE dengan tingkat error terkecil, yaitu diperoleh nilai RMSE 384,14 dan MAPE 5,75%. Hasil uji coba pada epoch 60 juga dapat dilihat pada visualisasi grafik, di mana garis warna merah menunjukkan nilai prediksi, yang telah mengikuti alur dari garis warna biru yang menunjukkan nilai yang aktual atau valid. Visualisasi grafik pada variabel price dapat dilihat pada gambar 16.



Gambar 16. Visualisasi Grafik Price

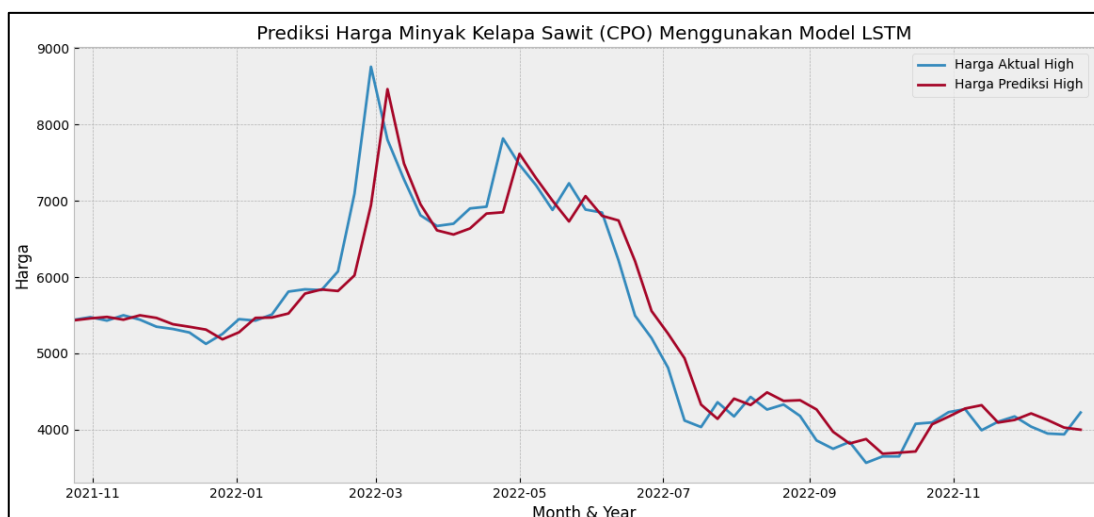
5.2.1.2 Hasil Pengujian Variabel High

Pengujian pada variabel *high* dengan percobaan nilai *epoch* yang berbeda yaitu *epoch* 10 – 70 dan 100 – 300. Sehingga mendapatkan hasil yang optimal dapat dilihat pada tabel 17.

Tabel 17. Pengujian Variabel High

Epoch	RMSE	MAPE
10	618,77	7,81%
20	493,24	5,57%
30	449,38	5,18%
40	483,26	5,49%
50	411,27	5,08%
60	389,63	4,30%
70	453,16	5,25%
...
100	420,02	4,68%
150	472,71	5,30%
200	520,24	5,74%
100	420,02	4,68%
150	472,71	5,30%

Tabel 17 menunjukkan hasil uji coba untuk dengan nilai epoch berbeda pada variabel *high*. Di mana epoch 60, memperoleh evaluasi RMSE dan MAPE dengan tingkat error terkecil, yaitu diperoleh nilai RMSE 389,63 dan MAPE 4,30%. Hasil uji coba pada epoch 60 juga dapat di lihat pada visualisasi grafik, sama seperti sebelumnya di mana garis warna merah menunjukkan nilai prediksi, yang telah mengikuti alur dari garis warna biru yang menunjukkan nilai yang aktual atau valid. Visualisasi grafik pada variabel *high* dapat dilihat pada gambar 17.



Gambar 17. Visualisasi Grafik High


5.2.1.3 Pengujian Variabel Low

Pengujian pada variabel *low* dengan percobaan nilai *epoch* yang berbeda yaitu *epoch* 10 – 70 dan 100 – 300. Sehingga mendapatkan hasil yang optimal dapat dilihat pada tabel 18.

Tabel 18. Pengujian Variabel Low

Epoch	RMSE	MAPE
10	525,53	8,17%
20	405,32	6,22%
30	345,42	5,25%
40	347,18	5,59%
50	311,37	4,65%
60	298,24	4,48%
70	428,68	6,87%
...
100	379,59	5,94%
150	461,99	7,17%
200	632,18	9,02%
250	1164,25	14,51%
300	1201,15	14,85%

Tabel 18 menunjukkan hasil uji coba untuk dengan nilai epoch berbeda pada variabel *low*. Di mana epoch 60, memperoleh evaluasi RMSE dan MAPE dengan tingkat error terkecil, yaitu diperoleh nilai RMSE 298,24 dan MAPE 4,48%. Hasil uji coba pada epoch 60 juga dapat di lihat pada visualisasi grafik, sama seperti sebelumnya di mana garis warna merah menunjukkan nilai prediksi, yang telah mengikuti alur dari garis warna biru yang menunjukkan nilai yang aktual atau valid. Visualisasi grafik pada variabel *low* dapat dilihat pada gambar 18.



Gambar 18. Visualisasi Grafik Low

5.2.2 Prediksi 5 Minggu Mendatang

Selanjutnya, pada penelitian ini melakukan skenario pengujian pada data harga minyak kelapa sawit (CPO) menggunakan pemodelan LSTM. Di mana skenario pengujian menggunakan nilai epoch yang berbeda dengan nilai evaluasi yang didapatkan disetiap pengujiannya. Berikut hasil pemodelan terbaik diperoleh pada epoch 60 dengan tingkat kesalahan RMSE dan MAPE terkecil. Hasil prediksi harga minyak kelapa sawit (CPO) dapat dilihat pada tabel 19.

Tabel 19. Hasil Prediksi 5 Minggu Mendatang

No	Tanggal	Hasil Prediksi Price		Hasil Prediksi High		Hasil Prediksi Low	
		Harga Prediksi	Harga Aktual	Harga Prediksi	Harga Aktual	Harga Prediksi	Harga Aktual
1.	01/01/2023	4007	3981	4061	4265	3847	3934
2.	08/01/2023	3869	3820	3921	4000	3750	3800
3.	15/01/2023	3755	3885	3803	3932	3662	3781
4.	22/01/2023	3661	3874	3703	3880	3580	3720
5.	29/01/2023	3584	3725	3621	3955	3506	3620
MAPE		2,91%		4,61%		2,72%	

Tabel 19 menunjukkan Tingkat akurasi prediksi harga minyak kelapa sawit (CPO) untuk 5 minggu mendatang dapat dikatakan sangat baik. Dengan akurasi MAPE untuk setiap variabel dibawah 10% yang meliputi variabel price sebesar 2,91%, high sebesar 4,61%, dan low sebesar 2,72%. Berdasarkan hasil, akurasi di

bawah 10% masuk ke dalam rentang yang sangat baik, seperti yang ditunjukkan pada Tabel 2.

BAB VI KESIMPULAN DAN SARAN

6.1 Kesimpulan

Data historis harga minyak kelapa sawit (CPO) dari tahun 2017–2022, yang telah berhasil membangun arsitektur pemodelan *Long Short Term Memory* (LSTM). Metode *Cross Industry Standart Process For Data Mining* (CRISP-DM) digunakan dalam penelitian ini. dengan menyiapkan dataset yang akan digunakan sebagai tahap pertama. Selanjutnya, tahap preprocessing data dan tahap pemodelan LSTM dilakukan. Setelah itu, model dievaluasi kinerjanya dengan menggunakan error model RMSE dan MAPE.

Data minyak kelapa sawit diperoleh dari website Investing.com sebanyak 313 digunakan dalam penelitian ini. Selain itu, penelitian ini akan menguji tiga variabel yaitu *price*, *high*, dan *low*. Sebelum proses preprocessing, data dinormalisasi menjadi rentang 0-1 dan dibagi menjadi 20% data uji (62 data) dan 80% data pelatihan (251 data). Selanjutnya, pada langkah pengujian model, nilai epoch yang berbeda digunakan, seperti 10, 20, 30, 40, 50, 60, dan 70, serta 100, 150, 200, 250, 300.

Berdasarkan Hasil uji coba menunjukkan bahwa model dengan variasi nilai *epoch* 10, 20, 30, 40, 50, 60, dan 70 memiliki tingkat akurasi terkecil pada epoch 60. Seperti, pada variabel *Price* memperoleh RMSE 384,14 dan MAPE 5,75%, variabel *High* memperoleh RMSE 389,63 dan MAPE 4,30%, dan variabel *Low* memperoleh RMSE 298,24 dan MAPE 4,48%. Sementara untuk model dengan nilai *epoch* 100, 150, 200, 250, 300, didapatkan tingkat akurasi pada RMSE dan MAPE semakin meningkat dengan nilai *epoch* yang makin besar di tambahkan.

Selanjutnya, hasil pengujian *epoch* 60 menunjukkan tingkat akurasi yang paling terkecil. Ini dapat digunakan untuk memprediksi harga selanjutnya, misalnya memprediksi harga selama 5 minggu pada januari 2023. dengan hasil setiap variabel menghasilkan hasil yang sangat baik. Seperti, pada variabel *Price* memperoleh MAPE 2,91%, diikuti *High* memperoleh MAPE 4,61%, dan *Low* memperoleh MAPE 2,72%. Dengan demikian, dapat disimpulkan bahwa algoritma *Long Short Term Memory* (LSTM) menunjukkan hasil prediksi pada harga minyak kelapa sawit (CPO) dengan tingkat kesalahan di bawah 10%, yang menunjukkan bahwa algoritma tersebut masuk ke dalam rentang kategori sangat baik.

6.2 Saran

Berikut saran berdasarkan hasil dari analisis dan kesimpulan, sebagai berikut:

1. Untuk penelitian selanjutnya dalam memprediksi harga minyak kelapa sawit, dapat menggunakan metode lain misalkan BiLSTM, sehingga dapat melihat perbandingan yang dihasilkan.
2. Untuk selanjutnya dalam pengujian bisa dikombinasikan dari segi parameter lainnya seperti nilai *neuron* dan *batch size* untuk mengukur tingkat akurasi yang didapatkan.

DAFTAR PUSTAKA

- Arfan, A., & ETP, L. (2020). Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia. *Petir*, 13(1), 33–43.
- Badan Pusat Statistik. (2023). <https://www.bps.go.id/>. Diakses pada 10 Oktober 2023.
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2022). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(3), 164–172.
- Ericko, T., Dolok Lauro, M., & Handhayani, T. (2023). Prediksi Harga Pangan Di Pasar Tradisional Kota Surabaya Dengan Metode Lstm. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 11(2).
- Firdaus, R., Mukhtar, H., & Awaluddin. (2023). Prediksi Indeks Harga Produsen Pertanian Karet Di Indonesia Menggunakan Metode LSTM. *Jurnal Fasilkom*, 13(01), 1–6.
- Hasibuan, L. S., & Novialdi, Y. (2022). Prediksi Harga Minyak Goreng Curah dan Kemasan Menggunakan Algoritme Long Short-Term Memory (LSTM). *Jurnal Ilmu Komputer Dan Agri-Informatika*, 9(2), 149–157.
- Hastomo, W., Karno, A. S. B., Kalbuana, N., Nisfiani, E., & ETP, L. (2021). Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19. *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)*, 7(2), 133–140.
- Huber, S., Wiemer, H., Schneider, D., & Ihlenfeldt, S. (2019). DMME: Data mining methodology for engineering applications - A holistic extension to the CRISP-DM model. *Procedia CIRP*, 79, 403–408.
- Investing.com. (2007). Palm Oil Futures. <https://www.investing.com/commodities/palm-oil-historical-data>. Diakses pada 10 Oktober 2023.
- Karno, A. S. B. (2020). Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Informatic and Information Security*, 1(1), 1–8.
- Kementrian Perdagangan Republik Indonesia. (2012). https://bappebti.go.id/harga_komoditi_bursa. Diakses pada 10 Oktober 2023.
- Lubis, N. H., & Lubis, Y. F. A. (2021). Implementasi Model Recurrent Neural Network Dalam Melakukan Prediksi Harga Kartu Perdana Internet Dengan Menggunakan Algoritma Long Short Term Memory. *SEMINAR NASIONAL TEKNOLOGI INFORMASI & KOMUNIKASI (Vol. 1, No. 1, Pp. 463-469)*.

- Qothrunnada, Kholida. (2022). Mengenal Pengertian Fluktuasi: Penyebab, Jenis, dan Contoh. <https://detik.com/jabar/bisnis/d-6237912/mengenal-pengertian-fluktuasi-penyebab-jenis-dan-contoh>. Diakses pada 22 Juni 2023.
- Rahayu, D., Wihandika, R. C., & Perdana, R. S. (2018). Implementasi Metode Backpropagation Untuk Klasifikasi Kenaikan Harga Minyak Kelapa Sawit. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(4 e-ISSN: 2548-964X), 1547–1552.
- Religia, Y., & Nurhasanah, N. (2019). KLASIFIKASI INVESTASI PADA RESIKO INVESTASI MINYAK KELAPA SAWIT MENGGUNAKAN ALGORITMA NAÏVE BAYES. *Jurnal SIGMA*, 10(2), 94–101.
- Rifa'i, A. (2020). Optimasi Fuzzy Artificial Neural Network dengan Algoritma Genetika untuk Prediksi Harga Crude Palm Oil. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 234–241.
- Riyantoko, P. A., Fahrudin, T. M., Hindrayani, K. M., & Safitri, E. M. (2020). Analisis Prediksi Harga Saham Sektor Perbankan Menggunakan Algoritma Long-Short Terms Memory (Lstm). *In Seminar Nasional Informatika (SEMNASIF)*, 1(1), 427–435.
- Rizkilloh, M. F., & Widiyanesti, S. (2022). Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(1), 25–31.
- Saadah, S. (2021). Support Vector Regression (SVR) Dalam Memprediksi Harga Minyak Kelapa Sawit di Indonesia dan Nilai Tukar Mata Uang EUR/USD. *Journal of Computer Science and Informatics Engineering (J-Cosine)*, 5(1), 85–92.
- Sanjaya, D., & Budi, S. (2020). Prediksi Pencapaian Target Kerja Menggunakan Metode Deep Learning dan Data Envelopment Analysis. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 288–300.
- Sanjaya, F. I., & Heksaputra, D. (2020). Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 7(2), 163–174.
- Simatupang, C. G. K., Swastika, W., & Suganda, T. R. (2022). Perancangan Aplikasi Berbasis Web Untuk Prediksi Harga Saham Dengan Metode Lstm. *Sainsbertek Jurnal Ilmiah Sains & Teknologi*, 3(1), 1–8.
- Supriyadi, E. (2021). Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (Lstm). *Jurnal Meteorologi Dan Geofisika*, 21(2), 55.

Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3), 620–627.

LAMPIRAN

Lampiran 1. Dataset Mingguan 2017 - 2022

Date	Price	Open	High	Low	Vol.	Change%
01/01/2017	3.200	3.241	3.250	3.153	0.79K	-0.56%
08/01/2017	3.280	3.219	3.330	3.170	1.01K	2.50%
15/01/2017	3.234	3.190	3.268	3.185	4.91K	-1.40%
22/01/2017	3.243	3.230	3.320	3.216	4.22K	0.28%
29/01/2017	3.250	3.230	3.267	3.205	0.98K	0.22%
05/02/2017	3.268	3.229	3.335	3.229	1.24K	0.55%
12/02/2017	3.094	3.300	3.306	3.088	3.02K	-5.32%
19/02/2017	2.977	3.095	3.119	2.885	7.64K	-3.78%
26/02/2017	3.000	2.964	3.005	2.866	1.65K	0.77%
05/03/2017	2.990	2.899	3.050	2.899	0.39K	-0.33%
12/03/2017	2.966	3.000	3.020	2.922	2.31K	-0.80%
19/03/2017	2.895	2.965	2.987	2.895	2.94K	-2.39%
26/03/2017	2.833	2.875	2.884	2.825	2.21K	-2.14%
02/04/2017	2.885	2.841	2.936	2.841	1.13K	1.84%
09/04/2017	2.750	2.861	2.871	2.736	1.64K	-4.68%
16/04/2017	2.669	2.665	2.680	2.574	8.07K	-2.95%
23/04/2017	2.694	2.629	2.726	2.598	3.05K	0.94%
30/04/2017	2.775	2.725	2.777	2.700	2.12K	3.01%
07/05/2017	2.860	2.787	2.896	2.775	1.94K	3.06%
14/05/2017	2.885	2.800	2.920	2.800	5.67K	0.87%
21/05/2017	2.840	2.915	2.922	2.840	3.41K	-1.56%
28/05/2017	2.730	2.830	2.830	2.727	3.55K	-3.87%
04/06/2017	2.680	2.728	2.746	2.670	2.35K	-1.83%
11/06/2017	2.656	2.670	2.675	2.630	3.25K	-0.90%
18/06/2017	2.589	2.682	2.699	2.576	3.77K	-2.52%
25/06/2017	2.596	2.614	2.632	2.579	2.98K	0.27%
02/07/2017	2.668	2.633	2.690	2.619	1.95K	2.77%
09/07/2017	2.620	2.700	2.705	2.665	1.10K	-1.80%
16/07/2017	2.612	2.642	2.648	2.550	5.53K	-0.31%
23/07/2017	2.666	2.587	2.708	2.578	4.39K	2.07%
30/07/2017	2.590	2.705	2.705	2.576	1.58K	-2.85%
06/08/2017	2.683	2.593	2.661	2.585	1.14K	3.59%
13/08/2017	2.675	2.600	2.680	2.588	3.57K	-0.30%
20/08/2017	2.733	2.670	2.780	2.665	5.10K	2.17%
27/08/2017	2.680	2.746	2.746	2.670	0.89K	-1.94%
03/09/2017	2.771	2.671	2.775	2.671	1.03K	3.40%
10/09/2017	2.885	2.780	2.818	2.780	0.35K	4.11%
17/09/2017	2.748	2.885	2.885	2.747	2.61K	-4.75%
24/09/2017	2.719	2.718	2.769	2.707	1.93K	-1.06%
01/10/2017	2.741	2.710	2.750	2.689	2.16K	0.81%
08/10/2017	2.716	2.750	2.750	2.670	0.55K	-0.91%
15/10/2017	2.724	2.751	2.758	2.700	2.48K	0.29%
22/10/2017	2.786	2.732	2.808	2.731	2.58K	2.28%
29/10/2017	2.784	2.825	2.828	2.775	0.82K	-0.07%

05/11/2017	2.740	2.765	2.794	2.723	0.86K	-1.58%
12/11/2017	2.680	2.770	2.770	2.676	1.85K	-2.19%
19/11/2017	2.545	2.659	2.659	2.530	2.84K	-5.04%
26/11/2017	2.495	2.525	2.525	2.450	1.38K	-1.96%
03/12/2017	2.379	2.519	2.519	2.386	0.56K	-4.65%
10/12/2017	2.346	2.375	2.395	2.300	0.57K	-1.39%
17/12/2017	2.407	2.479	2.479	2.382	3.63K	2.60%
24/12/2017	2.444	2.400	2.474	2.397	2.14K	1.54%
31/12/2017	2.570	2.466	2.561	2.466	1.31K	5.16%
07/01/2018	2.474	2.541	2.591	2.510	0.39K	-3.74%
14/01/2018	2.435	2.535	2.535	2.428	1.71K	-1.58%
21/01/2018	2.482	2.447	2.514	2.444	1.70K	1.93%
28/01/2018	2.475	2.500	2.519	2.468	0.77K	-0.28%
04/02/2018	2.495	2.451	2.510	2.451	1.53K	0.81%
11/02/2018	2.505	2.530	2.555	2.502	0.47K	0.40%
18/02/2018	2.536	2.497	2.551	2.493	6.97K	1.24%
25/02/2018	2.496	2.558	2.578	2.495	3.08K	-1.58%
04/03/2018	2.398	2.476	2.493	2.393	0.20K	-3.93%
11/03/2018	2.438	2.405	2.480	2.365	1.62K	1.67%
18/03/2018	2.420	2.434	2.466	2.390	5.04K	-0.74%
25/03/2018	2.380	2.390	2.415	2.330	1.00K	-1.65%
01/04/2018	2.479	2.400	2.454	2.400	0.66K	4.16%
08/04/2018	2.392	2.470	2.479	2.350	0.01K	-3.51%
15/04/2018	2.410	2.393	2.420	2.349	5.26K	0.75%
22/04/2018	2.378	2.404	2.405	2.375	1.24K	-1.33%
29/04/2018	2.319	2.370	2.371	2.310	0.92K	-2.48%
06/05/2018	2.359	2.354	2.365	2.354	0.10K	1.72%
13/05/2018	2.433	2.374	2.445	2.374	4.76K	3.14%
20/05/2018	2.453	2.451	2.481	2.427	4.27K	0.82%
27/05/2018	2.436	2.415	2.446	2.393	1.06K	-0.69%
03/06/2018	2.378	2.440	2.440	2.370	2.07K	-2.38%
10/06/2018	2.319	2.370	2.371	2.300	0.22K	-2.48%
17/06/2018	2.283	2.321	2.322	2.243	7.27K	-1.55%
24/06/2018	2.298	2.263	2.325	2.250	1.30K	0.66%
01/07/2018	2.255	2.290	2.300	2.250	0.10K	-1.87%
08/07/2018	2.140	2.272	2.272	2.138	0.07K	-5.10%
15/07/2018	2.180	2.143	2.208	2.138	4.50K	1.87%
22/07/2018	2.122	2.128	2.145	2.090	1.87K	-2.66%
29/07/2018	2.170	2.140	2.170	2.106	0.36K	2.26%
05/08/2018	2.206	2.180	2.249	2.180	0.11K	1.66%
12/08/2018	2.204	2.150	2.213	2.140	2.25K	-0.09%
19/08/2018	2.178	2.220	2.220	2.178	1.90K	-1.18%
26/08/2018	2.200	2.174	2.199	2.166	1.87K	1.01%
02/09/2018	2.213	2.187	2.240	2.187	0.25K	0.59%
09/09/2018	2.206	2.200	2.219	2.200	0.39K	-0.32%
16/09/2018	2.116	2.181	2.185	2.108	4.82K	-4.08%

23/09/2018	2.118	2.127	2.150	2.090	2.99K	0.09%
30/09/2018	2.139	2.114	2.149	2.060	0.60K	0.99%
07/10/2018	2.113	2.120	2.140	2.090	0.48K	-1.22%
14/10/2018	2.125	2.147	2.159	2.125	3.26K	0.57%
21/10/2018	2.046	2.124	2.150	2.045	4.03K	-3.72%
28/10/2018	1.985	2.048	2.080	1.942	2.07K	-2.98%
04/11/2018	1.880	2.005	2.005	1.950	0.07K	-5.29%
11/11/2018	1.775	1.854	1.856	1.757	2.59K	-5.59%
18/11/2018	1.866	1.775	1.920	1.775	4.65K	5.13%
25/11/2018	1.872	1.895	1.895	1.750	2.10K	0.32%
02/12/2018	1.793	1.882	1.887	1.756	0.49K	-4.22%
09/12/2018	1.835	1.830	2.055	1.828	0.19K	2.34%
16/12/2018	2.103	1.970	2.142	1.941	5.12K	14.60%
23/12/2018	2.013	2.092	2.103	2.007	1.38K	-4.28%
30/12/2018	2.120	2.025	2.121	2.003	0.46K	5.32%
06/01/2019	2.093	2.130	2.130	2.090	0.49K	-1.27%
13/01/2019	2.142	2.100	2.147	2.083	5.15K	2.34%
20/01/2019	2.190	2.156	2.202	2.147	1.97K	2.24%
27/01/2019	2.200	2.210	2.229	2.180	1.46K	0.46%
03/02/2019	2.190	2.227	2.238	2.190	0.35K	-0.45%
10/02/2019	2.200	2.230	2.230	2.190	0.40K	0.46%
17/02/2019	2.138	2.212	2.223	2.110	4.12K	-2.82%
24/02/2019	1.986	2.139	2.139	1.908	3.51K	-7.11%
03/03/2019	1.971	1.980	1.995	1.971	0.19K	-0.76%
10/03/2019	1.950	2.020	2.020	1.880	0.04K	-1.07%
17/03/2019	2.090	2.023	2.099	2.018	5.77K	7.18%
24/03/2019	2.001	2.075	2.075	1.994	2.61K	-4.26%
31/03/2019	2.129	2.000	2.160	1.996	0.64K	6.40%
07/04/2019	2.038	2.145	2.162	2.090	0.14K	-4.27%
14/04/2019	2.108	2.100	2.144	2.066	2.16K	3.43%
21/04/2019	2.013	2.113	2.117	2.011	1.09K	-4.51%
28/04/2019	1.900	2.008	2.013	1.923	1.25K	-5.61%
05/05/2019	1.920	1.956	1.961	1.900	0.11K	1.05%
12/05/2019	2.049	1.960	2.072	1.945	2.67K	6.72%
19/05/2019	1.976	2.057	2.060	1.960	1.17K	-3.56%
26/05/2019	2.030	2.000	2.047	1.979	1.91K	2.73%
02/06/2019	2.003	2.013	2.030	2.000	0.54K	-1.33%
09/06/2019	2.000	1.975	2.020	1.928	0.06K	-0.15%
16/06/2019	1.998	1.995	2.039	1.993	3.78K	-0.10%
23/06/2019	1.865	1.982	1.982	1.845	0.84K	-6.66%
30/06/2019	1.909	1.886	1.920	1.885	0.21K	2.36%
07/07/2019	1.900	1.893	1.972	1.870	0.05K	-0.47%
14/07/2019	1.905	1.911	1.924	1.896	0.84K	0.26%
21/07/2019	1.996	1.914	2.000	1.905	2.77K	4.78%
28/07/2019	2.013	1.990	2.019	1.990	0.39K	0.85%
04/08/2019	2.141	2.024	2.142	2.023	0.08K	6.36%

11/08/2019	2.143	2.152	2.180	2.130	0.99K	0.09%
18/08/2019	2.210	2.136	2.212	2.102	2.36K	3.13%
25/08/2019	2.168	2.250	2.253	2.115	1.14K	-1.90%
01/09/2019	2.116	2.145	2.155	2.070	0.73K	-2.40%
08/09/2019	2.105	2.130	2.145	2.110	0.20K	-0.52%
15/09/2019	2.161	2.223	2.230	2.158	2.40K	2.66%
22/09/2019	2.090	2.148	2.148	2.074	1.59K	-3.29%
29/09/2019	2.096	2.074	2.117	2.067	0.38K	0.29%
06/10/2019	2.118	2.104	2.156	2.103	0.17K	1.05%
13/10/2019	2.208	2.073	2.210	2.073	3.20K	4.25%
20/10/2019	2.309	2.213	2.340	2.184	2.34K	4.57%
27/10/2019	2.422	2.342	2.444	2.324	0.62K	4.89%
03/11/2019	2.526	2.420	2.561	2.420	0.12K	4.29%
10/11/2019	2.560	2.550	2.550	2.550	0.04K	1.35%
17/11/2019	2.642	2.503	2.645	2.477	1.93K	3.20%
24/11/2019	2.620	2.645	2.687	2.544	1.05K	-0.83%
01/12/2019	2.757	2.590	2.735	2.590	0.17K	5.23%
08/12/2019	2.816	2.825	2.850	2.775	0.27K	2.14%
15/12/2019	2.897	2.835	2.901	2.776	3.94K	2.88%
22/12/2019	3.035	2.907	3.058	2.890	1.11K	4.76%
29/12/2019	3.110	3.015	3.129	3.010	0.61K	2.47%
05/01/2020	3.131	3.060	3.132	3.035	0.25K	0.68%
12/01/2020	2.922	3.030	3.030	2.908	1.77K	-6.68%
19/01/2020	2.925	2.939	3.041	2.910	4.99K	0.10%
26/01/2020	2.640	2.780	2.794	2.629	1.09K	-9.74%
02/02/2020	2.872	2.647	2.940	2.647	0.56K	8.79%
09/02/2020	2.660	2.800	2.824	2.655	0.16K	-7.38%
16/02/2020	2.683	2.710	2.735	2.598	3.53K	0.86%
23/02/2020	2.357	2.666	2.669	2.350	1.78K	-12.15%
01/03/2020	2.448	2.415	2.566	2.350	0.55K	3.86%
08/03/2020	2.302	2.328	2.420	2.320	0.88K	-5.96%
15/03/2020	2.338	2.307	2.507	2.241	5.74K	1.56%
22/03/2020	2.487	2.296	2.488	2.295	1.51K	6.37%
29/03/2020	2.320	2.589	2.591	2.335	0.89K	-6.71%
05/04/2020	2.389	2.335	2.430	2.335	0.13K	2.97%
12/04/2020	2.285	2.340	2.340	2.245	0.82K	-4.35%
19/04/2020	2.121	2.286	2.320	2.065	1.87K	-7.18%
26/04/2020	2.102	2.075	2.114	2.018	1.09K	-0.90%
03/05/2020	2.060	2.060	2.060	2.000	1.11K	-2.00%
10/05/2020	2.115	2.060	2.130	2.020	0.52K	2.67%
17/05/2020	2.240	2.149	2.276	2.149	3.56K	5.91%
24/05/2020	2.373	2.280	2.373	2.280	0.95K	5.94%
31/05/2020	2.405	2.377	2.470	2.377	1.60K	1.35%
07/06/2020	2.433	2.446	2.450	2.382	0.34K	1.16%
14/06/2020	2.538	2.420	2.538	2.406	4.29K	4.32%
21/06/2020	2.473	2.508	2.551	2.458	2.14K	-2.56%

28/06/2020	2.421	2.411	2.441	2.379	1.16K	-2.10%
05/07/2020	2.467	2.435	2.480	2.410	0.52K	1.90%
12/07/2020	2.699	2.475	2.702	2.475	1.98K	9.40%
19/07/2020	2.890	2.732	2.900	2.706	3.76K	7.08%
26/07/2020	2.780	2.866	2.881	2.654	1.24K	-3.81%
02/08/2020	2.885	2.880	2.909	2.840	1.29K	3.78%
09/08/2020	2.803	2.850	2.950	2.799	1.23K	-2.84%
16/08/2020	2.798	2.800	2.852	2.735	3.92K	-0.18%
23/08/2020	2.845	2.790	2.861	2.705	4.47K	1.68%
30/08/2020	2.932	2.898	2.995	2.862	1.29K	3.06%
06/09/2020	2.880	2.930	2.940	2.874	0.24K	-1.77%
13/09/2020	3.102	2.888	3.103	2.888	2.48K	7.71%
20/09/2020	2.930	3.108	3.121	2.830	5.84K	-5.54%
27/09/2020	2.846	2.946	2.965	2.829	2.84K	-2.87%
04/10/2020	3.020	2.850	3.028	2.823	0.60K	6.11%
11/10/2020	2.985	3.060	3.060	2.960	0.84K	-1.16%
18/10/2020	3.064	2.958	3.078	2.879	3.64K	2.65%
25/10/2020	3.252	3.120	3.370	3.117	2.57K	6.14%
01/11/2020	3.405	3.181	3.475	3.181	2.98K	4.70%
08/11/2020	3.549	3.405	3.510	3.387	0.83K	4.23%
15/11/2020	3.483	3.487	3.627	3.475	6.30K	-1.86%
22/11/2020	3.505	3.450	3.520	3.390	4.41K	0.63%
29/11/2020	3.645	3.468	3.695	3.420	1.23K	3.99%
06/12/2020	3.709	3.674	3.722	3.628	1.13K	1.76%
13/12/2020	3.663	3.660	3.750	3.549	5.06K	-1.24%
20/12/2020	3.854	3.656	3.877	3.613	4.76K	5.21%
27/12/2020	3.891	3.849	3.900	3.800	2.47K	0.96%
03/01/2021	3.997	3.950	4.040	3.905	2.24K	2.72%
10/01/2021	3.815	3.968	3.980	3.750	1.22K	-4.55%
17/01/2021	3.583	3.640	3.659	3.435	7.11K	-6.08%
24/01/2021	3.935	3.529	3.935	3.529	5.44K	9.82%
31/01/2021	3.914	3.890	4.010	3.690	3.72K	-0.53%
07/02/2021	3.898	3.925	3.960	3.850	1.89K	-0.41%
14/02/2021	3.914	3.930	4.025	3.868	5.74K	0.41%
21/02/2021	3.986	3.995	4.056	3.920	6.15K	1.84%
28/02/2021	3.947	4.027	4.050	3.847	3.77K	-0.98%
07/03/2021	4.283	4.040	4.330	4.020	0.85K	8.51%
14/03/2021	4.013	4.257	4.277	3.972	3.82K	-6.30%
21/03/2021	4.025	4.022	4.305	4.000	4.90K	0.30%
28/03/2021	4.147	4.000	4.160	3.954	4.18K	3.03%
04/04/2021	4.280	4.165	4.370	4.135	2.40K	3.21%
11/04/2021	4.191	4.225	4.300	4.160	2.31K	-2.08%
18/04/2021	4.351	4.181	4.500	4.147	5.38K	3.82%
25/04/2021	4.408	4.419	4.504	4.299	4.76K	1.31%
02/05/2021	4.883	4.578	4.885	4.520	3.61K	10.78%
09/05/2021	4.800	4.810	4.923	4.785	1.08K	-1.70%

16/05/2021	4.391	4.724	4.839	4.371	12.02K	-8.52%
23/05/2021	4.301	4.330	4.385	4.196	5.48K	-2.05%
30/05/2021	4.230	4.284	4.300	3.990	4.18K	-1.65%
06/06/2021	3.859	4.150	4.182	4.020	0.37K	-8.77%
13/06/2021	3.593	3.590	3.615	3.434	3.32K	-6.89%
20/06/2021	3.702	3.580	3.708	3.530	5.83K	3.03%
27/06/2021	3.898	3.620	3.950	3.620	4.68K	5.29%
04/07/2021	4.020	3.887	4.040	3.870	2.11K	3.13%
11/07/2021	4.300	3.985	4.317	3.985	3.00K	6.97%
18/07/2021	4.542	4.343	4.586	4.300	6.81K	5.63%
25/07/2021	4.656	4.523	4.740	4.489	2.71K	2.51%
01/08/2021	4.520	4.490	4.634	4.430	1.79K	-2.92%
08/08/2021	4.530	4.508	4.655	4.453	0.34K	0.22%
15/08/2021	4.514	4.647	4.740	4.448	8.12K	-0.35%
22/08/2021	4.560	4.419	4.619	4.419	7.04K	1.02%
29/08/2021	4.550	4.581	4.595	4.420	3.66K	-0.22%
05/09/2021	4.574	4.541	4.769	4.538	1.20K	0.53%
12/09/2021	4.518	4.610	4.700	4.445	2.97K	-1.22%
19/09/2021	4.665	4.430	4.705	4.400	6.89K	3.25%
26/09/2021	4.751	4.700	4.848	4.576	3.85K	1.84%
03/10/2021	5.152	4.781	5.139	4.781	2.08K	8.44%
10/10/2021	5.160	5.135	5.170	5.080	0.34K	0.16%
17/10/2021	5.188	5.094	5.440	5.070	6.54K	0.54%
24/10/2021	5.402	5.240	5.440	5.180	4.40K	4.12%
31/10/2021	5.319	5.400	5.475	5.316	1.81K	-1.54%
07/11/2021	5.405	5.254	5.430	5.200	1.99K	1.62%
14/11/2021	5.437	5.375	5.500	5.236	6.47K	0.59%
21/11/2021	5.269	5.380	5.442	5.255	4.23K	-3.09%
28/11/2021	5.175	5.315	5.350	5.125	2.89K	-1.78%
05/12/2021	5.242	5.300	5.320	5.180	2.14K	1.29%
12/12/2021	4.879	5.250	5.274	4.736	4.03K	-6.92%
19/12/2021	5.121	4.878	5.125	4.755	5.66K	4.96%
26/12/2021	5.159	5.130	5.255	5.079	5.59K	0.74%
02/01/2022	5.330	5.260	5.449	5.217	3.01K	3.31%
09/01/2022	5.300	5.333	5.430	5.240	1.08K	-0.56%
16/01/2022	5.504	5.260	5.510	5.232	7.21K	3.85%
23/01/2022	5.803	5.500	5.810	5.390	8.03K	5.43%
30/01/2022	5.779	5.840	5.840	5.675	0.70K	-0.41%
06/02/2022	5.800	5.760	5.830	5.455	0.48K	0.36%
13/02/2022	6.008	5.870	6.075	5.762	6.27K	3.59%
20/02/2022	6.718	6.100	7.093	6.100	7.79K	11.82%
27/02/2022	6.780	6.890	8.757	6.724	4.04K	0.92%
06/03/2022	7.365	7.000	7.800	6.950	0.60K	8.63%
13/03/2022	6.116	7.000	7.280	6.105	3.67K	-16.96%
20/03/2022	6.616	6.188	6.810	6.151	7.25K	8.18%
27/03/2022	6.363	6.629	6.670	6.177	3.94K	-3.82%

03/04/2022	6.681	6.380	6.700	6.321	1.28K	5.00%
10/04/2022	6.820	6.700	6.900	6.700	0.28K	2.08%
17/04/2022	6.871	6.701	6.923	6.691	8.91K	0.75%
24/04/2022	7.683	7.020	7.817	6.820	4.09K	11.82%
01/05/2022	7.058	7.473	7.473	6.945	1.41K	-8.13%
08/05/2022	6.950	7.050	7.204	6.900	0.69K	-1.53%
15/05/2022	6.689	6.719	6.880	6.400	7.22K	-3.76%
22/05/2022	6.879	6.705	7.230	6.703	9.84K	2.84%
29/05/2022	6.704	6.830	6.885	6.536	3.75K	-2.54%
05/06/2022	6.281	6.750	6.846	6.350	0.81K	-6.31%
12/06/2022	5.679	6.044	6.219	5.566	2.95K	-9.58%
19/06/2022	4.798	5.460	5.495	4.660	11.00K	-15.51%
26/06/2022	4.886	4.887	5.201	4.737	7.85K	1.83%
03/07/2022	4.137	4.812	4.812	3.850	1.90K	-15.33%
10/07/2022	3.632	4.120	4.120	3.632	0.13K	-12.21%
17/07/2022	3.727	3.688	4.035	3.648	9.22K	2.62%
24/07/2022	4.355	3.728	4.360	3.696	5.23K	16.85%
31/07/2022	4.020	4.100	4.174	3.909	0.52K	-7.69%
07/08/2022	4.432	4.100	4.430	4.100	0.28K	10.25%
14/08/2022	4.090	4.113	4.264	4.049	3.89K	-7.72%
21/08/2022	4.149	4.250	4.330	4.092	3.70K	1.44%
28/08/2022	3.830	4.162	4.180	3.793	1.59K	-7.69%
04/09/2022	3.500	3.820	3.859	3.450	0.28K	-8.62%
11/09/2022	3.700	3.530	3.750	3.530	0.47K	5.71%
18/09/2022	3.673	3.722	3.840	3.560	6.05K	-0.73%
25/09/2022	3.327	3.550	3.566	3.143	3.51K	-9.42%
02/10/2022	3.630	3.307	3.650	3.300	0.64K	9.11%
09/10/2022	3.650	3.540	3.650	3.508	0.05K	0.55%
16/10/2022	3.979	3.778	4.077	3.692	7.71K	9.01%
23/10/2022	3.826	4.062	4.095	3.750	4.36K	-3.85%
30/10/2022	4.182	3.915	4.230	3.795	2.23K	9.30%
06/11/2022	4.187	4.200	4.270	4.020	0.57K	0.12%
13/11/2022	3.791	3.993	3.993	3.746	3.79K	-9.46%
20/11/2022	4.060	3.796	4.105	3.750	5.06K	7.10%
27/11/2022	3.905	4.123	4.174	3.900	2.77K	-3.82%
04/12/2022	3.924	3.890	4.040	3.820	0.35K	0.49%
11/12/2022	3.863	3.780	3.950	3.680	2.02K	-1.55%
18/12/2022	3.802	3.904	3.939	3.791	7.02K	-1.58%
25/12/2022	4.171	3.950	4.225	3.950	5.70K	9.71%

Lampiran 2. Data Normalisasi Pada Variabel Price, High, Low

Normalisasi Price	Normalisasi High	Normalisasi Low
0,2412	0,2020	0,2698
0,2547	0,2136	0,2731
0,2470	0,2046	0,2760
0,2485	0,2121	0,2819
0,2497	0,2045	0,2798
0,2527	0,2143	0,2844
0,2233	0,2101	0,2573
0,2035	0,1830	0,2183
0,2073	0,1665	0,2146
0,2057	0,1730	0,2210
0,2016	0,1687	0,2254
0,1896	0,1639	0,2202
0,1791	0,1490	0,2067
0,1879	0,1565	0,2098
0,1650	0,1471	0,1896
0,1513	0,1194	0,1585
0,1556	0,1261	0,1631
0,1693	0,1335	0,1827
0,1836	0,1507	0,1971
0,1879	0,1542	0,2019
0,1803	0,1545	0,2096
0,1616	0,1411	0,1879
0,1532	0,1290	0,1769
0,1491	0,1187	0,1692
0,1378	0,1222	0,1588
0,1390	0,1124	0,1594
0,1512	0,1209	0,1671
0,1430	0,1230	0,1760
0,1417	0,1148	0,1538
0,1508	0,1235	0,1592
0,1379	0,1230	0,1588
0,1537	0,1166	0,1606
0,1523	0,1194	0,1612
0,1622	0,1339	0,1760
0,1532	0,1290	0,1769
0,1686	0,1332	0,1771
0,1879	0,1394	0,1981
0,1647	0,1491	0,1917
0,1598	0,1323	0,1840
0,1635	0,1295	0,1806
0,1593	0,1295	0,1769
0,1606	0,1307	0,1827
0,1711	0,1380	0,1887
0,1708	0,1408	0,1971

0,1633	0,1359	0,1871
0,1532	0,1324	0,1781
0,1303	0,1164	0,1500
0,1219	0,0969	0,1346
0,1022	0,0961	0,1223
0,0966	0,0781	0,1058
0,1070	0,0903	0,1215
0,1132	0,0896	0,1244
0,1346	0,1022	0,1377
0,1183	0,1065	0,1462
0,1117	0,0984	0,1304
0,1197	0,0953	0,1335
0,1185	0,0961	0,1381
0,1219	0,0948	0,1348
0,1236	0,1013	0,1446
0,1288	0,1007	0,1429
0,1220	0,1046	0,1433
0,1055	0,0923	0,1237
0,1122	0,0904	0,1183
0,1092	0,0884	0,1231
0,1024	0,0810	0,1115
0,1192	0,0867	0,1250
0,1044	0,0903	0,1154
0,1075	0,0817	0,1152
0,1021	0,0796	0,1202
0,0921	0,0746	0,1077
0,0988	0,0738	0,1162
0,1114	0,0853	0,1200
0,1148	0,0906	0,1302
0,1119	0,0855	0,1237
0,1021	0,0846	0,1192
0,0921	0,0746	0,1058
0,0860	0,0675	0,0948
0,0885	0,0680	0,0962
0,0812	0,0643	0,0962
0,0618	0,0603	0,0746
0,0686	0,0510	0,0746
0,0587	0,0419	0,0654
0,0669	0,0455	0,0685
0,0730	0,0569	0,0827
0,0726	0,0517	0,0750
0,0682	0,0527	0,0823
0,0719	0,0497	0,0800
0,0741	0,0556	0,0840
0,0730	0,0526	0,0865
0,0577	0,0477	0,0688

0,0581	0,0426	0,0654
0,0616	0,0425	0,0596
0,0572	0,0412	0,0654
0,0592	0,0439	0,0721
0,0459	0,0426	0,0567
0,0355	0,0325	0,0369
0,0178	0,0216	0,0385
0	0	0,0013
0,0154	0,0093	0,0048
0,0164	0,0057	0
0,0030	0,0045	0,0012
0,0102	0,0288	0,0150
0,0555	0,0414	0,0367
0,0403	0,0358	0,0494
0,0584	0,0384	0,0487
0,0538	0,0397	0,0654
0,0621	0,0422	0,0640
0,0702	0,0501	0,0763
0,0719	0,0541	0,0827
0,0702	0,0554	0,0846
0,0719	0,0542	0,0846
0,0614	0,0532	0,0692
0,0357	0,0410	0,0304
0,0332	0,0201	0,0425
0,0296	0,0238	0,0250
0,0533	0,0352	0,0515
0,0383	0,0317	0,0469
0,0599	0,0441	0,0473
0,0445	0,0443	0,0654
0,0564	0,0417	0,0608
0,0403	0,0378	0,0502
0,0212	0,0228	0,0333
0,0245	0,0152	0,0288
0,0464	0,0313	0,0375
0,0340	0,0296	0,0404
0,0432	0,0277	0,0440
0,0386	0,0252	0,0481
0,0381	0,0238	0,0342
0,0377	0,0265	0,0467
0,0152	0,0183	0,0183
0,0227	0,0093	0,0260
0,0212	0,0168	0,0231
0,0220	0,0099	0,0281
0,0374	0,0209	0,0298
0,0403	0,0236	0,0462
0,0619	0,0414	0,0525

0,0623	0,0469	0,0731
0,0736	0,0516	0,0677
0,0665	0,0575	0,0702
0,0577	0,0433	0,0615
0,0559	0,0419	0,0692
0,0653	0,0542	0,0785
0,0533	0,0423	0,0623
0,0543	0,0378	0,0610
0,0581	0,0435	0,0679
0,0733	0,0513	0,0621
0,0904	0,0701	0,0835
0,1095	0,0852	0,1104
0,1271	0,1022	0,1288
0,1329	0,1006	0,1538
0,1468	0,1143	0,1398
0,1430	0,1204	0,1527
0,1662	0,1274	0,1615
0,1762	0,1440	0,1971
0,1899	0,1514	0,1973
0,2133	0,1742	0,2192
0,2260	0,1845	0,2423
0,2295	0,1849	0,2471
0,1941	0,1701	0,2227
0,1947	0,1717	0,2231
0,1464	0,1359	0,1690
0,1857	0,1571	0,1725
0,1498	0,1403	0,1740
0,1537	0,1274	0,1631
0,0985	0,1178	0,1154
0,1139	0,1029	0,1154
0,0892	0,0817	0,1096
0,0953	0,0943	0,0944
0,1205	0,0916	0,1048
0,0922	0,1065	0,1125
0,1039	0,0832	0,1125
0,0863	0,0701	0,0952
0,0586	0,0672	0,0606
0,0553	0,0374	0,0515
0,0482	0,0296	0,0481
0,0575	0,0397	0,0519
0,0787	0,0609	0,0767
0,1012	0,0749	0,1019
0,1066	0,0890	0,1206
0,1114	0,0861	0,1215
0,1291	0,0988	0,1262
0,1181	0,1007	0,1362

0,1093	0,0848	0,1210
0,1171	0,0904	0,1269
0,1564	0,1226	0,1394
0,1887	0,1513	0,1838
0,1701	0,1485	0,1738
0,1879	0,1526	0,2096
0,1740	0,1585	0,2017
0,1732	0,1443	0,1894
0,1811	0,1456	0,1837
0,1958	0,1650	0,2138
0,1870	0,1571	0,2162
0,2246	0,1807	0,2188
0,1955	0,1833	0,2077
0,1813	0,1607	0,2075
0,2107	0,1698	0,2063
0,2048	0,1745	0,2327
0,2182	0,1771	0,2171
0,2500	0,2194	0,2629
0,2759	0,2346	0,2752
0,3003	0,2397	0,3148
0,2891	0,2566	0,3317
0,2928	0,2411	0,3154
0,3165	0,2665	0,3212
0,3274	0,2704	0,3612
0,3196	0,2745	0,3460
0,3519	0,2929	0,3583
0,3582	0,2962	0,3942
0,3761	0,3165	0,4144
0,3453	0,3078	0,3846
0,3060	0,2613	0,3240
0,3656	0,3013	0,3421
0,3621	0,3121	0,3731
0,3593	0,3049	0,4038
0,3621	0,3143	0,4073
0,3742	0,3188	0,4173
0,3676	0,3179	0,4033
0,4245	0,3585	0,4365
0,3788	0,3508	0,4273
0,3808	0,3549	0,4327
0,4015	0,3339	0,4238
0,4240	0,3643	0,4587
0,4089	0,3542	0,4635
0,4360	0,3831	0,4610
0,4457	0,3837	0,4902
0,5261	0,4389	0,5327
0,5120	0,4444	0,5837

0,4428	0,4323	0,5040
0,4276	0,3665	0,4704
0,4155	0,3542	0,4308
0,3527	0,3371	0,4365
0,3077	0,2549	0,3238
0,3262	0,2684	0,3423
0,3593	0,3034	0,3596
0,3800	0,3165	0,4077
0,4274	0,3566	0,4298
0,4683	0,3956	0,4904
0,4876	0,4179	0,5267
0,4646	0,4026	0,5154
0,4663	0,4056	0,5198
0,4636	0,4179	0,5188
0,4714	0,4004	0,5133
0,4697	0,3969	0,5135
0,4738	0,4221	0,5362
0,4643	0,4121	0,5183
0,4892	0,4128	0,5096
0,5037	0,4336	0,5435
0,5716	0,4757	0,5829
0,5730	0,4802	0,6404
0,5777	0,5193	0,6385
0,6139	0,5193	0,6596
0,5999	0,5244	0,6858
0,6144	0,5179	0,6635
0,6198	0,5280	0,6704
0,5914	0,5196	0,6740
0,5755	0,5063	0,6490
0,5868	0,5020	0,6596
0,5254	0,4953	0,5742
0,5664	0,4737	0,5779
0,5728	0,4925	0,6402
0,6017	0,5206	0,6667
0,5966	0,5179	0,6712
0,6312	0,5295	0,6696
0,6818	0,5730	0,7000
0,6777	0,5773	0,7548
0,6813	0,5759	0,7125
0,7165	0,6114	0,7715
0,8367	0,7589	0,8365
0,8472	1	0,9565
0,9462	0,8613	1
0,7348	0,7860	0,8375
0,8194	0,7179	0,8463
0,7766	0,6976	0,8513

0,8304	0,7019	0,8790
0,8539	0,7309	0,9519
0,8626	0,7342	0,9502
1	0,8638	0,9750
0,8942	0,8139	0,9990
0,8759	0,7750	0,9904
0,8318	0,7280	0,8942
0,8639	0,7787	0,9525
0,8343	0,7287	0,9204
0,7627	0,7231	0,8846
0,6608	0,6322	0,7338
0,5117	0,5273	0,5596
0,5266	0,4847	0,5744
0,3998	0,4283	0,4038
0,3143	0,3281	0,3619
0,3304	0,3158	0,3650
0,4367	0,3628	0,3742
0,3800	0,3359	0,4152
0,4497	0,3730	0,4519
0,3918	0,3489	0,4421
0,4018	0,3585	0,4504
0,3478	0,3368	0,3929
0,2920	0,2902	0,3269
0,3258	0,2745	0,3423
0,3213	0,2875	0,3481
0,2627	0,2478	0,2679
0,3140	0,2600	0,2981
0,3174	0,2600	0,3381
0,3731	0,3218	0,3735
0,3472	0,3244	0,3846
0,4074	0,3440	0,3933
0,4083	0,3498	0,4365
0,3412	0,3097	0,3838
0,3868	0,3259	0,3846
0,3605	0,3359	0,4135
0,3637	0,3165	0,3981
0,3534	0,3034	0,3712
0,3431	0,3018	0,3925
0,4056	0,3433	0,4231