

**ANALISIS KINERJA METODE *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION* PADA MODEL *PROPHET* UNTUK PREDIKSI INDEKS HARGA SAHAM GABUNGAN (IHSG)**

**Skripsi**

**Oleh**

**M. FARHAN ABOERUSLAN M  
NPM. 2217031132**



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

**2026**

## ABSTRACT

### ANALYSIS OF BAYESIAN OPTIMIZATION HYPERPARAMETER TUNING PERFORMANCE ON THE PROPHET MODEL FOR FORECASTING THE INDONESIA COMPOSITE STOCK PRICE INDEX (IHSG)

By

**M. Farhan Aboeruslan M**

The Indonesia Composite Stock Price Index (IHSG) is an important indicator that reflects the condition of the Indonesian stock market and tends to exhibit fluctuating movements. The ability to accurately forecast IHSG movements is essential to support investment decision-making. This study employs the Prophet method because of its capability to flexibly model time series data with trend and seasonal patterns. The data used consist of secondary data in the form of daily IHSG closing prices from January 2020 to December 2025 obtained from Investing.com. The research stages include data preprocessing, data visualization, splitting the data into training data (80%) and testing data (20%), developing the baseline Prophet model, hyperparameter optimization using Bayesian Optimization, and evaluating the forecasting results. The results show that the implementation of Bayesian Optimization improves the performance of the Prophet model by producing lower prediction error rates. In addition, the best model is used to forecast the IHSG for the next 30 days. The forecasting results are expected to provide useful insights for investors in making investment decisions in the capital market.

**Kata-kata kunci:** Indonesia Composite Stock Price Index, Prophet, Forecasting, Bayesian Optimization, Hyperparameter Tuning, Time Series.

## ABSTRAK

### ANALISIS KINERJA METODE *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION* PADA MODEL *PROPHET* UNTUK PREDIKSI INDEKS HARGA SAHAM GABUNGAN (IHSG)

Oleh

**M. Farhan Aboeruslan M**

Indeks Harga Saham Gabungan (IHSG) merupakan indikator penting yang menggambarkan kondisi pasar saham di Indonesia dan memiliki pergerakan yang cenderung fluktuatif. Kemampuan dalam memprediksi pergerakan IHSG secara tepat sangat diperlukan untuk mendukung pengambilan keputusan investasi. Penelitian ini menggunakan metode *Prophet* karena mampu memodelkan data deret waktu dengan pola tren dan musiman secara fleksibel. Data yang digunakan berupa data sekunder harga penutupan harian IHSG periode Januari 2020 hingga Desember 2025 yang diperoleh dari situs Investing.com. Tahapan penelitian meliputi *preprocessing* data, visualisasi data, pembagian data menjadi data latih (80%) dan data uji (20%), pembangunan model *Prophet baseline*, optimisasi hyperparameter menggunakan *Bayesian Optimization*, serta evaluasi hasil prediksi. Hasil penelitian menunjukkan bahwa penerapan *Bayesian Optimization* dapat meningkatkan kinerja model *Prophet* dengan menghasilkan tingkat kesalahan prediksi yang lebih rendah. Selain itu, model terbaik digunakan untuk melakukan prediksi IHSG selama 30 hari ke depan. Hasil prediksi tersebut diharapkan dapat menjadi bahan pertimbangan bagi investor dalam menentukan keputusan investasi di pasar modal.

**Kata-kata kunci:** Indeks Harga Saham, *Prophet*, Peramalan, *Bayesian Optimization*, *Hyperparameter Tuning*, Deret Waktu.

**ANALISIS KINERJA METODE *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION* PADA MODEL *PROPHET* UNTUK PREDIKSI INDEKS HARGA SAHAM GABUNGAN (IHSG)**

**M. FARHAN ABOERUSLAN M**

**Skripsi**

Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



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

**2026**

**Judul Skripsi : ANALISIS KINERJA METODE  
HYPERPARAMETER TUNING BAYESIAN  
OPTIMIZATION PADA MODEL PROPHET  
UNTUK PREDIKSI INDEKS HARGA  
SAHAM GABUNGAN (IHSG)**

**Nama Mahasiswa : M. Farhan Aboeruslan M**

**Nomor Pokok Mahasiswa : 2217031132**

**Program Studi : Matematika**

**Fakultas : Matematika dan Ilmu Pengetahuan Alam**



**1. Komisi Pembimbing**



**Dr. Subian Saidi, S.Si., M.Si.**  
NIP. 198008212008121001



**Dr. Bernadhita H. S. U, S.Si., M.Sc.**  
NIP. 199206302023212034

**2. Wakil Dekan Bidang Akademik dan Kerjasama  
FMIPA Universitas Lampung**



**Mulyono, S.Si., M.Si., Ph.D.**  
NIP. 197406112000031002

**MENGESAHKAN**

**1. Tim Penguji**

**Ketua : Dr. Subian Saidi, S.Si., M.Si.**



**Sekretaris : Dr. Bernadhita H. S. U, S.Si., M.Sc.**



**Penguji Bukan Pembimbing : Dr. Khoirin Nisa, S.Si., M.Si.**



**2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**



**Dr. Eng. Heri Satria, S.Si., M.Si.**

**NIP. 197110012005011002**

**Tanggal Lulus Ujian Skripsi: 4 Mei 2026**

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **M. Farhan Aboeruslan M**  
Nomor Pokok Mahasiswa : **2217031132**  
Jurusan : **Matematika**  
Judul Skripsi : **ANALISIS KINERJA METODE  
HYPERPARAMETER TUNING BAYESIAN  
OPTIMIZATION PADA MODEL PROPHET  
UNTUK PREDIKSI INDEKS HARGA  
SAHAM GABUNGAN (IHSG)**

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

Bandar Lampung, 4 Mei 2026



M. Farhan Aboeruslan M

## **RIWAYAT HIDUP**

Penulis bernama lengkap M. Farhan Aboeruslan M yang lahir di Jakarta pada tanggal 26 September 2004. Penulis merupakan anak kedua dari Bapak Heri Mulyadi dan Deasylina W.

Penulis menempuh pendidikan Sekolah Dasar (SDS) Cindera Mata Harapan Indah pada tahun 2010-2016, Sekolah Menengah Pertama (SMPS) Cindera Mata Harapan Indah pada tahun 2016-2019, Sekolah Menengah Atas (SMAS) Soedirman 2 Bekasi 2019-2022.

Pada tahun 2022, penulis melanjutkan pendidikan Sarjana (S1) di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Pengalaman organisasi penulis yaitu menjadi Anggota Bidang Keilmuan HIMATIKA FMIPA Unila Periode 2023.

Pada bulan Desember 2024 – Februari 2025 penulis melaksanakan Kerja Praktik (KP) di Leica Geosystem Indonesia. Pada bulan Juli 2025 Penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Teluk Betung Utara, Kecamatan Teluk, Kota Bandar Lampung, Provinsi Lampung.

## KATA INSPIRASI

“Boleh jadi sesuatu yang tampak sulit hari ini menyimpan hikmah besar di masa depan.”

— QS. Al-Kahfi: 60-82

“Sesungguhnya Allah Maha Mengetahui apa yang tersembunyi di balik setiap perjuangan.”

— QS. Al-Mulk: 13-14

“Maka apabila engkau telah selesai dari suatu urusan, tetaplah bekerja keras untuk urusan yang lain.”

— QS. Al-Insyirah: 7

## **PERSEMBAHAN**

Dengan mengucapkan Alhamdulillah dan bersyukur kepada Allah SWT atas karunia dan petunjuk-Nya, sehingga tugas akhir ini dapat diselesaikan dengan baik dan sesuai waktunya. Dengan penuh rasa syukur dan kebahagiaan, saya ucapkan terimakasih kepada:

### **Keluargaku Tersayang**

Terima kasih untuk ibu Deasylina, Bapak Heri M, Kakak Fawwaz, dan Almh Adik Zizi selalu mendoakan tanpa henti, memberi dukungan, pengorbanan, perhatian, cinta, dan kasih sayang yang diberikan untuk kelancaran setiap langkah yang aku pilih. Karena atas doa dan ridho semua, Allah juga memberikan kemudahan untuk setiap langkah yang aku lalui. Terima kasih sudah menjadi orang tua yang luar biasa dan selalu mengajarkan hal-hal baik. Semoga aku bisa tumbuh menjadi anak yang membanggakan dunia, akhirat dan berguna bagi banyak orang.

### **Dosen Pembimbing dan Pembahas**

Terima kasih sudah meluangkan waktu untuk membimbing dan mengarahkan saya dalam menyelesaikan skripsi ini. Semua masukan dan saran yang diberikan sangat membantu saya menjadi lebih baik.

### **Sahabat-sahabatku**

Terima kasih sudah menjadi teman yang baik selama masa kuliah yaitu infinity dumb yang sudah berjuang bersama selama ini. Terima kasih juga sudah saling membantu, menyemangati, dan menemani di saat susah maupun senang.

### **Almamater Tercinta**

Universitas Lampung

## SANWACANA

Segala puji dan syukur dipanjatkan atas kehadiran Allah SWT., karena berkat rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi dengan judul "Analisis Kinerja Metode Hyperparameter Tuning Bayesian Optimization Pada Model Prophet Untuk Prediksi Indeks Harga Saham Gabungan (IHSG)" dengan baik, lancar, dan sesuai dengan tenggat waktu yang telah ditetapkan. Semoga shalawat dan salam senantiasa diberikan kepada Nabi Muhammad SAW.

Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Bapak Dr. Subian Saidi, S.Si., M.Si. selaku dosen Pembimbing I yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Bernadhita Herindri Samodera Utami, S.Si., M.Sc., selaku dosen pembimbing II yang senantiasa memberikan arahan, bantuan, dan saran kepada penulis dalam menyusun skripsi ini.
3. Ibu Dr. Khoirin Nisa, S.Si., M.Si. selaku dosen Pembahas yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Ibu Drs. Fitriani, s.Si., M.Sc. selaku dosen pembimbing akademik.
6. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Terima kasih Papa, Bunda yang selama ini tidak pernah lelah mendoakan penulis di setiap saat. Motivasi dan semangat yang selalu kalian berikan membuat penulis terus berjalan. Selain itu selalu mengingatkan penulis untuk bersyukur dalam setiap kondisi. Tanpa doa dan ridho Papa dan Bunda, penulis tidak mungkin berada di titik ini.
8. Untuk keluarga besarku, Kaka Fawwaz, Almh Fauziah, Nenek, Uwa, yang selalu mendoakan dan mendukung dari awal sampai tahap akhir ini.
9. Sahabat perjuanganku sejak awal hingga sekarang, Widya Febriyana, Anggun Dwi Maharani, Aurelia Daffa Raihan Mariyam, Fika Nazma Khoiriah, Katarina Vani Wulandari, Leony Putri Kinanti, Aini Rahmawati, Aurora Kirei Fatimah A, Adhitya Kusuma Putra, Muhammad Dzaki Hidayat, teman-teman KKN Teluk Betung Utara, dan Twice yang telah memberi semangat dan dukungan kepada penulis selama masa perkuliahan.
10. Teman-teman seperjuangan Jurusan Matematika angkatan 2022.
11. Seluruh pihak terkait yang membantu dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari laporan ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan baik dalam penyajian maupun teknik penulisan. Oleh sebab itu, saran dan kritikan yang membangun senantiasa penulis harapkan dari seluru pihak. Penulis berharap skripsi ini bermanfaat oleh pembaca dan penulis sendiri.

Bandar Lampung, 4 Mei 2026

M. Farhan Aboeruslan M

## DAFTAR ISI

<b>DAFTAR ISI</b> . . . . .	<b>xiii</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xiv</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xiv</b>
<b>I PENDAHULUAN</b> . . . . .	<b>1</b>
1.1 Latar Belakang dan Masalah . . . . .	1
1.2 Tujuan Penelitian . . . . .	3
1.3 Manfaat Penelitian . . . . .	3
<b>II TINJAUAN PUSTAKA</b> . . . . .	<b>4</b>
2.1 Peramalan ( <i>forecasting</i> ) . . . . .	4
2.2 Analisis Deret Waktu . . . . .	4
2.3 <i>Prophet</i> . . . . .	5
2.4 Struktur <i>Prophet</i> . . . . .	7
2.5 Parameter Utama <i>Prophet</i> . . . . .	9
2.6 Parameter Tuning dan <i>Bayesian Optimizaiton</i> . . . . .	9
2.6.1 <i>Gaussian Process</i> (GP) . . . . .	10
2.6.2 Formulasi Optimasi . . . . .	10
2.6.3 <i>Acquisition Function (Expected Improvement)</i> . . . . .	11
2.7 Evaluasi Model . . . . .	12
2.8 Indeks Harga Saham Gabungan (IHSG) . . . . .	14
<b>III METODE PENELITIAN</b> . . . . .	<b>15</b>
3.1 Waktu dan Tempat Penelitian . . . . .	15
3.2 Data Penelitian . . . . .	15
3.3 Metode Penelitian . . . . .	15
<b>IV HASIL DAN PEMBAHASAN</b> . . . . .	<b>21</b>
4.1 <i>Preprocessing</i> Data . . . . .	21
4.1.1 Pemilihan Variabel Dataset . . . . .	21
4.1.2 Pembersihan <i>Missing Values</i> . . . . .	21
4.1.3 Pembagian Data . . . . .	22
4.2 Analisis deskriptif . . . . .	22

4.3	Pembangunan model <i>Prophet Baseline</i> . . . . .	24
4.4	Pembangunan model <i>Hyperparameter Tuning Prophet Baseline</i> dengan <i>Bayesian Optimization</i> . . . . .	29
4.5	Evaluasi Model . . . . .	35
4.6	Perbandingan Hasil Peramalan . . . . .	36
4.7	<i>Forecasting</i> . . . . .	37
<b>V</b>	<b>PENUTUP</b> . . . . .	<b>43</b>
5.1	Kesimpulan . . . . .	43
	<b>DAFTAR PUSTAKA</b> . . . . .	<b>44</b>

## DAFTAR TABEL

1.	Kriteria Nilai MAPE . . . . .	13
2.	<i>Hyperparameter search space</i> . . . . .	17
3.	Hasil Perhitungan Statistika Deskriptif . . . . .	23
4.	Perolehan parameter Model <i>Prophet Baseline</i> pada IHSG . . . . .	27
5.	Indikator <i>Seasonality (t)</i> . . . . .	28
6.	Hasil <i>hyperparameter tuning</i> Model <i>Prophet Baseline</i> dengan <i>Bayesian Optimization</i> . . . . .	31
7.	Perolehan Parameter Model <i>Prophet</i> dengan <i>Bayesian Optimization</i>	31
8.	Indikator <i>Seasonality (t)</i> . . . . .	34
9.	Evaluasi Model . . . . .	35
10.	Perolehan parameter dengan Model <i>Prophet Bayesian Optimized</i> . .	37
11.	Indikator <i>Seasonality (t)</i> . . . . .	39
12.	<i>Forecasting 30 Hari</i> . . . . .	42

## DAFTAR GAMBAR

1.	<i>Flowchart</i> Alur Penelitian . . . . .	20
2.	Plot Pembagian Data . . . . .	22
3.	Plot Pembagian Data . . . . .	24
4.	Plot perbandingan <i>Prophet Baseline</i> vs <i>Prophet Bayesian Optimized</i>	36
5.	Plot <i>Forecasting</i> Final . . . . .	41

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang dan Masalah

Peramalan (*forecasting*) merupakan proses penting dalam pengambilan keputusan yang bertujuan untuk memperkirakan nilai atau kejadian di masa depan berdasarkan pola data historis (Makridakis *et al.*, 2019). Dalam konteks ekonomi dan keuangan, peramalan digunakan secara luas untuk memprediksi harga saham, tingkat inflasi, suku bunga, serta berbagai indikator makro ekonomi lainnya. Hyndman dan Athanasopoulos (2018) mengklasifikasikan metode peramalan ke dalam pendekatan utama, yaitu metode kualitatif dan kuantitatif. Metode kualitatif mengandalkan intuisi, pengalaman, atau pendapat para ahli ketika ketersediaan data historis terbatas, sedangkan metode kuantitatif memanfaatkan data masa lalu yang tersedia untuk dianalisis secara statistik sehingga menghasilkan prediksi yang objektif dan terukur (Gujarati & Porter, 2020).

Salah satu pendekatan kuantitatif yang paling banyak digunakan dalam bidang keuangan adalah analisis deret waktu (*time series analysis*), yaitu metode analisis terhadap data yang tersusun berdasarkan urutan waktu untuk mengidentifikasi pola tren, musiman, dan siklus (Chatfield, 2019). Data harga saham, seperti Indeks Harga Saham Gabungan (IHSG), merupakan contoh klasik dari data deret waktu karena pergerakannya diamati secara periodik setiap hari perdagangan dan mencerminkan dinamika pasar secara real-time (Tsay, 2010). Oleh karena itu, dalam memahami dan memprediksi pola data deret waktu menjadi sangat krusial bagi investor maupun pengambilan kebijakan ekonomi.

Dengan meningkatnya kompleksitas data keuangan, metode peramalan tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) sering kali tidak mampu menangkap perubahan mendadak dan non-linearitas dalam data pasar saham (Zhang, 2003). Untuk mengatasi keterbatasan tersebut, *Facebook* memperkenalkan

model *Prophet* sebuah metode peramalan berbasis *additive model* yang mampu menangani tren non-linear, efek musiman, serta *change point* atau titik perubahan secara otomatis (Taylor & Letham, 2018). Metode *Prophet* dirancang agar mudah digunakan bahkan untuk data yang tidak sepenuhnya bersih dan cocok diterapkan dalam berbagai konteks bisnis maupun ekonomi.

Kelebihan utama Metode *Prophet* terletak pada kemampuannya dalam menangani data dengan pola yang kompleks melalui pemisahan komponen tren dan musiman, serta toleransinya terhadap data yang hilang (*missing values*). Selain itu, *Prophet* memiliki fleksibilitas yang tinggi dalam penyesuaian parameter, seperti *change point prior scale* dan *seasonality prior scale*, yang berfungsi untuk mengontrol sensitivitas model terhadap perubahan tren dan tingkat kompleksitas musiman (Taylor & Letham, 2018). Namun, penggunaan parameter *default* pada Metode *Prophet* sering kali belum mampu menghasilkan kinerja prediksi yang optimal, karena nilai parameter tersebut bersifat umum dan tidak selalu sesuai dengan karakteristik data yang spesifik (Hyndman & Athanasopoulos, 2021). Kondisi ini menjadi semakin relevan pada data pasar saham seperti Indeks Harga Saham Gabungan (IHSG) yang bersifat volatil dan sangat sensitif terhadap faktor eksternal.

Untuk meningkatkan kinerja model *Prophet*, pendekatan *Bayesian Optimization* (BO) mulai banyak digunakan sebagai metode *hyperparameter tuning*. *Bayesian Optimization* bekerja dengan mencari kombinasi parameter terbaik melalui proses probabilistik yang efisien, sehingga mampu mengurangi kebutuhan eksplorasi parameter secara menyeluruh sebagaimana pada metode pencarian *grid* konvensional (Snoek *et al.*, 2012). Dengan menggabungkan Metode *Prophet* dan *Bayesian Optimization*, proses penyesuaian parameter menjadi lebih adaptif terhadap karakteristik data, yang pada akhirnya dapat menghasilkan prediksi yang lebih akurat serta menurunkan nilai kesalahan peramalan, seperti *Mean Absolute Percentage Error* (MAPE).

Beberapa penelitian terdahulu menunjukkan bahwa kombinasi *Prophet* dengan *Bayesian Optimization* mampu meningkatkan akurasi hasil peramalan. Penelitian oleh Hamdani *et al* (2023) menunjukkan bahwa penggunaan *Bayesian Optimization* pada model *Prophet* meningkatkan akurasi prediksi harga minyak mentah dibandingkan dengan model *Prophet default*. Sementara itu, penelitian oleh Alfoin dan Herawati (2024) menunjukkan bahwa model *Prophet* dengan optimisasi

*Bayesian* lebih unggul dalam memprediksi pergerakan saham LQ45 dibandingkan model tradisional seperti ARIMA dan LSTM. Penelitian serupa oleh Ying *et al* (2005) juga mengonfirmasi bahwa pendekatan ini efektif dalam meminimalkan *error* prediksi pada data ekonomi makro.

Melihat potensi tersebut, penelitian ini berfokus pada analisis kinerja model *Prophet Default* dan *Prophet* dengan *Bayesian Optimization* dalam memprediksi harga penutupan Indeks Harga Saham Gabungan (IHSG). IHSG dipilih karena mencerminkan kondisi keseluruhan pasar saham Indonesia dan menjadi indikator penting bagi stabilitas ekonomi nasional. Diharapkan hasil penelitian ini dapat memberikan kontribusi dalam pengembangan model peramalan saham yang lebih akurat serta menjadi referensi bagi investor dan pengambil kebijakan dalam pengelolaan risiko investasi.

## **1.2 Tujuan Penelitian**

Adapun tujuan dari penelitian ini adalah:

1. menganalisis kinerja model *Prophet* dalam melakukan prediksi harga penutupan Indeks Harga Saham Gabungan (IHSG);
2. menerapkan *Bayesian Optimization* untuk melakukan optimisasi parameter pada model *Prophet* agar memperoleh hasil prediksi yang lebih akurat;
3. menilai efektivitas optimisasi parameter terhadap peningkatan performa model *Prophet* dalam konteks data pasar saham Indonesia.

## **1.3 Manfaat Penelitian**

Adapun manfaat dari penelitian ini adalah:

1. hasil penelitian ini diharapkan dapat memberikan literatur mengenai pengaruh optimisasi parameter terhadap peningkatan kinerja model *forecasting*;
2. penelitian ini dapat memberikan rekomendasi bagi investor, analisa keuangan, dan pembuat kebijakan dalam memahami dan memprediksi pergerakan Indeks Harga Saham Gabungan (IHSG).

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Peramalan (*forecasting*)**

Peramalan (*forecasting*) merupakan proses memperkirakan nilai di masa depan berdasarkan pola yang terbentuk dari data historis (Hyndman & Athanasopoulos., 2021). Dalam dunia keuangan, peramalan digunakan untuk membantu investor, analis, dan pembuat kebijakan dalam mengambil keputusan berbasis data. Metode peramalan dibedakan menjadi dua jenis, yaitu kualitatif dan kuantitatif. Metode kualitatif mengandalkan intuisi dan pendapat ahli, sementara metode kuantitatif menggunakan data numerik untuk dianalisis secara matematis dan statistik (Makridakis *et al.*, 2019; Armstrong, 2001).

Peramalan deret waktu (*time series forecasting*) termasuk dalam metode kuantitatif karena menggunakan data yang disusun berdasarkan waktu. Tujuannya adalah mengidentifikasi pola seperti tren, musiman, dan fluktuasi acak agar dapat digunakan untuk memperkirakan nilai di masa depan (Chatfield, 2019). Dalam konteks pasar modal, metode ini menjadi penting karena harga saham dan indeks seperti IHSG menunjukkan perilaku yang bergantung pada waktu, volatilitas, dan reaksi terhadap peristiwa ekonomi global.

#### **2.2 Analisis Deret Waktu**

Analisis deret waktu (*time series analysis*) digunakan untuk memahami hubungan antara nilai masa lalu dan nilai masa depan dari suatu variabel yang diamati secara berurutan dalam interval waktu tertentu (Box *et al.*, 2016). Dalam konteks pasar saham, data deret waktu umumnya menunjukkan beberapa pola utama, yaitu tren jangka panjang, pola musiman, serta fluktuasi acak. Oleh karena itu, model peramalan yang baik harus menangkap ketiga karakteristik tersebut secara simultan.

Berdasarkan karakteristiknya, data deret waktu dapat diklasifikasikan ke dalam beberapa tipe, antara lain deret waktu stasioner dan non-stasioner, deret waktu musiman, serta deret waktu dengan volatilitas tinggi dan perubahan struktural (*change point*) yang sering ditemukan pada data pasar keuangan (Hyndman & Athanasopoulos, 2021). Data harga saham, termasuk Indeks Harga Saham Gabungan (IHSG), umumnya bersifat non-stasioner dan volatil sehingga memerlukan model peramalan yang fleksibel dan adaptif.

Sebelum berkembangnya model peramalan modern berbasis *machine learning*, metode klasik seperti *Autoregressive Integrated Moving Average* (ARIMA) dan Exponential Smoothing banyak digunakan dalam analisis deret waktu. Namun, metode tersebut memiliki keterbatasan dalam menangkap hubungan non-linear serta perubahan mendadak yang sering terjadi pada data finansial (Zhang, 2003; Box *et al.*, 2016). Oleh karena itu, model peramalan modern seperti *Prophet* dan pendekatan berbasis optimisasi probabilistik mulai banyak diterapkan karena memiliki fleksibilitas yang lebih tinggi dalam menyesuaikan pola data yang kompleks.

### 2.3 Prophet

Model *Prophet* merupakan metode peramalan deret waktu yang dikembangkan oleh Facebook (Meta) pada tahun 2017 untuk menangani data dengan pola tren dan musiman yang kompleks (Taylor & Letham, 2018). Model ini dirancang agar mudah digunakan, fleksibel, serta mampu bekerja dengan baik pada data yang tidak sepenuhnya bersih, sehingga banyak diterapkan dalam konteks bisnis dan ekonomi. *Prophet* menggunakan pendekatan *additive* model, yaitu data deret waktu dimodelkan sebagai penjumlahan dari beberapa komponen utama, yaitu tren, musiman, dan efek hari libur atau peristiwa khusus. Model *Prophet* secara umum dapat ditulis dengan persamaan berikut (Nurhasanah *et al.*, 2023):

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (2.3.1)$$

dengan:

$$\begin{aligned}y(t) &= \text{nilai aktual pada waktu } t \\g(t) &= \text{komponen tren (trend)} \\s(t) &= \text{komponen musiman (seasonality)} \\h(t) &= \text{komponen hari libur atau peristiwa khusus (holiday)} \\\varepsilon_t &= \text{error (residual noise)}\end{aligned}$$

Komponen tren pada *Prophet* dimodelkan menggunakan fungsi *piecewise* linear atau *logistic growth* yang memungkinkan adanya perubahan pola tren dari waktu ke waktu. Perubahan tersebut dideteksi melalui mekanisme *automatic changepoint detection*.

Komponen musiman dimodelkan menggunakan fungsi *Fourier series*, sehingga *Prophet* mampu menangkap pola musiman harian, mingguan, maupun tahunan. Selain itu, *Prophet* juga memungkinkan penambahan efek hari libur atau peristiwa khusus yang dapat memengaruhi nilai deret waktu secara signifikan (Taylor & Letham, 2018).

*Prophet* menyediakan beberapa parameter penting yang dapat disesuaikan untuk meningkatkan kinerja model, di antaranya *changepoint prior scale* yang mengatur sensitivitas model terhadap perubahan tren, serta *seasonality prior scale* yang mengontrol kompleksitas komponen musiman. Nilai parameter yang terlalu kecil dapat menyebabkan model kurang responsif terhadap perubahan data, sedangkan nilai yang terlalu besar berpotensi menyebabkan *overfitting*.

Keunggulan utama Metode *Prophet* terletak pada kemampuannya menangani data dengan pola tren dan musiman yang kompleks, toleransinya terhadap data hilang (*missing values*), serta kemudahan dalam proses implementasi. Selain itu, *Prophet* tidak mengharuskan data bersifat stasioner, sehingga cocok diterapkan pada data pasar saham yang umumnya bersifat non-stasioner dan volatil.

Meskipun memiliki berbagai keunggulan, *Prophet* juga memiliki beberapa keterbatasan. Model ini cenderung kurang optimal dalam menangkap fluktuasi ekstrem jangka pendek serta sangat bergantung pada pemilihan parameter awal yang tepat. Beberapa penelitian menunjukkan bahwa penggunaan parameter default *Prophet* sering kali belum menghasilkan akurasi prediksi yang optimal, terutama pada data keuangan yang memiliki volatilitas tinggi. Keterbatasan

tersebut mendorong pengembangan model lanjutan seperti *NeuralProphet* yang mengintegrasikan pendekatan neural networks untuk meningkatkan kemampuan menangkap pola non-linear (Triebe *et al.*, 2018).

## 2.4 Struktur *Prophet*

Menurut Taylor & Letham (2018), *Prophet* memecah data deret waktu menjadi tiga komponen utama sebagai berikut:

- a. Komponen Tren Komponen ini merepresentasikan arah umum data dari waktu ke waktu, apakah meningkat, menurun, atau stabil. *Prophet* memiliki dua jenis tren:

### 1. *Linear Trend*

$$g(t) = (k + a(t)^T \delta) t + (m + a(t)^T \gamma) \quad (2.4.2)$$

dengan  $k$  adalah laju pertumbuhan (*growth rate*),  $m$  adalah intersep,  $t$  adalah waktu yang dinormalisasi,  $T$  adalah transpose,  $\delta$  adalah perubahan *slope* tren,  $\gamma$  adalah penyesuaian intersep.  $\delta$  memiliki *rate adjustments*,  $\gamma_j$  diatur ke  $-s_j \delta_j$  untuk membuat fungsi kontinu dan  $a(t)$  menunjukkan lokasi titik perubahan (*change points*).

### 2. *Logistic Growth Trend*

$$g(t) = \frac{c}{1 + \exp(-(k + a(t)^T \delta)(t - (m + a(t)^T \gamma)))}, \quad -\infty < t < \infty \quad (2.4.3)$$

dengan untuk data dengan batas atas (*cap*)  $C$ ,  $k$  adalah laju pertumbuhan (*growth rate*), adalah  $m$  intersep,  $\delta_j$  adalah perubahan rate yang terjadi pada waktu  $s_j$ .

Parameter *change point prior scale* mengontrol seberapa sensitif model terhadap perubahan tren. Nilai tinggi membuat tren lebih fleksibel, sedangkan nilai kecil membuatnya lebih halus.

- b. **Komponen Musiman** Komponen musiman menggambarkan pola berulang dalam data. *Prophet* menggunakan fungsi *Fourier Series* untuk menangkap variasi periode:

$$s(t) = \sum_{n=1}^N \left( a_n \sin \left( \frac{2\pi nt}{P} \right) + b_n \cos \left( \frac{2\pi nt}{P} \right) \right) \quad (2.4.4)$$

dengan parameter  $\beta = [a_1, b_1, \dots, a_N, b_N]^T$ . Hal ini dilakukan dengan membangun matriks vektor musiman untuk setiap nilai  $t$  dalam data historis dan masa depan. Sebagai contoh untuk *yearly seasonality* dengan  $P=365,25$  dan  $N=10$ .

$$X(t) = \left[ \sin \left( \frac{2\pi(1)t}{365.25} \right), \dots, \cos \left( \frac{2\pi(10)t}{365.25} \right) \right] \quad (2.4.5)$$

Sehingga komponen musiman menjadi seperti berikut:

$$s(t) = X(t)\beta \quad (2.4.6)$$

Dalam model *generative* ini ditetapkan  $\beta \sim Normal(0, \sigma^2)$ , untuk pemulusan sebelum pada musiman. Kemudian  $P$  adalah periode regular dari deret waktu, dan  $N$  untuk menerapkan *low pass filter* pada musiman. Sehingga  $N$  memungkinkan penyesuaian pola musiman akan berubah lebih cepat, meskipun akan meningkatkan resiko *overfitting*.

- c. **Komponen Hari Libur**

Komponen ini memperhitungkan dampak hari-hari tertentu, seperti hari libur nasional atau peristiwa besar ekonomi, dengan fungsi:

$$h(t) = Z(t)\kappa, \quad -\infty < t < \infty \quad (2.4.7)$$

dengan  $Z(t)$  adalah matriks indikator hari libur dan  $\kappa$  adalah koefisien dampaknya terhadap hasil prediksi.

## 2.5 Parameter Utama *Prophet*

*Prophet* memiliki sejumlah parameter penting yang berperan dalam mengontrol perilaku model, di antaranya :

1. *changepoint prior scale* = mengatur seberapa sensitif model terhadap perubahan tren. Nilai yang lebih tinggi membuat model lebih adaptif, tetapi berisiko *overfitting*.
2. *seasonality prior scale* = menentukan seberapa kuat komponen musiman memengaruhi hasil prediksi.
3. *holidays prior scale* = mengontrol efek peristiwa khusus seperti libur nasional atau kejadian eksternal.
4. *seasonality mode* = mengatur apakah komponen musiman bersifat *additive* atau *multiplicative*.

Pemilihan nilai parameter yang tepat sangat memengaruhi kinerja model *Prophet*. Penelitian oleh Li *et al.*, (2021) menunjukkan bahwa pengaturan parameter yang tidak sesuai dapat menyebabkan peramalan menjadi bias atau kehilangan sensitivitas terhadap perubahan tren jangka pendek. Oleh karena itu, parameter *optimization* menjadi langkah penting dalam meningkatkan akurasi prediksi *Prophet*.

## 2.6 Parameter Tuning dan *Bayesian Optimizaiton*

Parameter tuning merupakan proses mencari kombinasi parameter terbaik yang menghasilkan performa model paling optimal (Eriksson *et al.*, 2019). Pendekatan sederhana seperti *grid search* dan *random search* memerlukan banyak waktu dan sumber daya komputasi karena mencoba semua kombinasi secara eksplisit (Cowen-Rivers *et al.*, 2020).

Sebagai solusi yang lebih efisien, *Bayesian Optimization* (BO) diperkenalkan untuk melakukan pencarian parameter terbaik secara probabilistik (Springenberg *et al.*, 2016). *Bayesian Optimization* (BO) merupakan metode optimasi yang digunakan untuk mencari parameter optimal secara efisien pada fungsi objektif yang mahal untuk dievaluasi. Metode ini bekerja dengan membangun model probabilistik sebagai

pendekatan terhadap fungsi objektif, sehingga tidak perlu mengevaluasi seluruh kombinasi parameter secara langsung (Acerbi & Ma, 2017).

### 2.6.1 Gaussian Process (GP)

Dalam *Bayesian Optimization*, model probabilistik yang umum digunakan adalah *Gaussian Process* (GP). *Gaussian Process* merupakan model probabilistik non-parametrik yang digunakan untuk memodelkan hubungan antara kombinasi parameter dan nilai fungsi objektif. GP tidak hanya memberikan prediksi nilai rata-rata (*mean*), tetapi juga tingkat ketidakpastian (*variance* atau *standard deviation*) dari prediksi tersebut. Secara matematis, *Gaussian Process* dapat dinyatakan sebagai:

$$f(\theta) \sim GP(\mu(\theta), k(\theta, \theta')) \quad (2.6.8)$$

dengan:

- $\mu(\theta)$  adalah fungsi rata-rata (*mean*),
- $k(\theta, \theta')$  adalah fungsi kovarians (*kernel*) yang menunjukkan tingkat kemiripan antar parameter.

Melalui GP, setiap kombinasi parameter akan memiliki dua informasi penting, yaitu nilai prediksi rata-rata  $\mu(\theta)$  dan ketidakpastian  $\sigma(\theta)$ . Informasi ini digunakan untuk memperkirakan performa parameter yang belum diuji. Dengan demikian, GP berfungsi sebagai *surrogate* model yang menggantikan fungsi objektif asli yang mahal untuk dihitung, sehingga proses optimasi menjadi lebih efisien.

### 2.6.2 Formulasi Optimasi

Tujuan dari *Bayesian Optimization* adalah mencari kombinasi parameter optimal yang meminimalkan fungsi objektif. Secara matematis, permasalahan ini dapat dirumuskan sebagai berikut (Acerbi & Ma, 2017):

$$\theta^* = \arg \min_{\theta \in \Theta} f(\theta) \quad (2.6.9)$$

dengan:

- $\theta$  adalah kombinasi parameter,

- $\Theta$  adalah domain parameter,
- $f(\theta)$  adalah fungsi objektif.

dalam penelitian ini, fungsi objektif yang digunakan adalah *Mean Absolute Percentage Error* (MAPE), yang didefinisikan sebagai:

$$f(\theta) = MAPE(\hat{y}, y) \quad (2.6.10)$$

di mana  $\hat{y}$  adalah nilai prediksi dan  $y$  adalah nilai aktual. MAPE merupakan salah satu metrik evaluasi yang umum digunakan dalam peramalan karena memberikan interpretasi kesalahan dalam bentuk persentase (Makridakis *et al.*, 2019).

### 2.6.3 Acquisition Function (Expected Improvement)

Untuk menentukan kombinasi parameter berikutnya yang akan diuji, *Bayesian Optimization* menggunakan fungsi yang disebut *acquisition function*. Salah satu *acquisition function* yang umum digunakan adalah *Expected Improvement* (EI).

*Expected Improvement* bertujuan untuk memilih parameter yang memiliki potensi memberikan perbaikan terhadap nilai terbaik yang telah diperoleh sebelumnya. EI mempertimbangkan dua hal, yaitu nilai prediksi rata-rata dan tingkat ketidakpastian dari *Gaussian Process*, sehingga mampu menyeimbangkan antara eksploitasi (*exploitation*) dan eksplorasi (*exploration*) (Klein *et al.*, 2017; Snoek *et al.*, 2012). Secara matematis, *Expected Improvement* dirumuskan sebagai:

$$EI(\theta) = (f_{\min} - \mu(\theta)) \Phi(z) + \sigma(\theta) \phi(z) \quad (2.6.11)$$

dengan:

$$z = \frac{f_{\min} - \mu(\theta)}{\sigma(\theta)} \quad (2.6.12)$$

di mana:

- $f_{\min}$  adalah nilai fungsi objektif terbaik saat ini,
- $\mu(\theta)$  adalah prediksi rata-rata dari *Gaussian Process*,
- $\sigma(\theta)$  adalah standar deviasi dari *Gaussian Process*,

- $\Phi(z)$  adalah fungsi distribusi kumulatif normal standar,
- $\phi(z)$  adalah fungsi kepadatan probabilitas normal standar.

Nilai EI yang tinggi menunjukkan bahwa suatu kombinasi parameter memiliki potensi besar untuk memberikan peningkatan performa model.

Dalam penelitian ini, *Bayesian Optimization* digunakan untuk melakukan tuning parameter pada model *Prophet*. Parameter yang dioptimasi antara lain *changepoint prior scale*, *seasonality prior scale*, dan parameter lainnya yang memengaruhi fleksibilitas model terhadap pola tren dan musiman.

Dengan menggunakan *Gaussian Process* sebagai model probabilistik dan *Expected Improvement* sebagai fungsi akuisisi, proses pencarian parameter menjadi lebih efisien karena hanya mengevaluasi kombinasi parameter yang paling menjanjikan. Hal ini memungkinkan model *Prophet* mencapai keseimbangan antara kompleksitas dan akurasi prediksi secara optimal (Bou-Ammar & Osborne, 2023).

## 2.7 Evaluasi Model

Evaluasi model merupakan tahap penting dalam penelitian prediksi deret waktu karena berfungsi untuk menilai sejauh mana model mampu menghasilkan prediksi yang akurat dan efisien. Tanpa proses evaluasi, sulit untuk menentukan apakah model yang digunakan sudah memberikan hasil terbaik atau perlu dilakukan penyesuaian parameter. Menurut Hyndman & Athanasopoulos (2018), evaluasi model peramalan dilakukan dengan cara membandingkan nilai prediksi dengan nilai aktual dari data historis menggunakan berbagai metrik kesalahan (*error metrics*).

Dalam konteks model *Prophet*, evaluasi kinerja biasanya dilakukan dengan menggunakan data *train* dan *test* atau melalui teknik *cross validation* untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat. Beberapa metrik umum yang digunakan dalam evaluasi model peramalan antara lain *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *Root Mean Squared Error* (RMSE) (Makridakis *et al.*, 2019).

### 1. Mean Absolute Error

MAE mengukur rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi tanpa memperhatikan arah kesalahan. Metrik ini memberikan gambaran umum seberapa jauh hasil prediksi dari nilai sebenarnya dalam satuan yang sama dengan data asli. Nilai MAE yang lebih kecil menunjukkan kinerja model yang lebih baik.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad i = 1, \dots, n \quad (2.7.13)$$

### 2. Mean Absolute Percentage Error

MAPE merupakan metrik yang paling umum digunakan dalam penelitian finansial karena menampilkan kesalahan dalam bentuk persentase, sehingga mudah diinterpretasikan. MAPE dihitung sebagai rata-rata dari persentase selisih antara nilai aktual dan nilai prediksi. Namun, MAPE memiliki kelemahan ketika nilai aktual mendekati nol, karena dapat menyebabkan nilai kesalahan menjadi sangat besar (Armstrong & Collopy, 1992).

Tabel 1. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
$MAPE < 10\%$	Kemampuan peramalan yang sangat baik
$10\% \leq MAPE < 20\%$	Kemampuan peramalan yang baik
$20\% \leq MAPE < 50\%$	Kemampuan peramalan yang cukup
$MAPE \geq 50\%$	Kemampuan peramalan yang buruk

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad i = 1, \dots, n \quad (2.7.14)$$

### 3. Root Mean Squared Error (RMSE)

RMSE digunakan untuk mengukur seberapa besar deviasi antara nilai prediksi dengan nilai aktual, dengan memberikan penalti lebih besar terhadap kesalahan yang besar karena adanya proses kuadrat. Metrik ini sensitif terhadap *outlier*, namun efektif untuk mendeteksi model yang menghasilkan kesalahan besar pada sebagian data (Chai & Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad i = 1, \dots, n \quad (2.7.15)$$

#### 4. *Cross-Validation*

Model *Prophet* memiliki fitur bawaan untuk melakukan *cross-validation* berbasis waktu, yang disebut *time-based cross-validation*. Berbeda dengan *k-fold cross-validation* tradisional pada data non-waktu, pendekatan ini membagi data berdasarkan urutan waktu, bukan secara acak (Taylor & Letham, 2018). Tujuannya adalah untuk mensimulasikan situasi prediksi di masa depan dengan hanya menggunakan data historis yang sudah tersedia. *Prophet* menyediakan fungsi *cross validation* dan *performance metrics* untuk menghitung metrik evaluasi seperti MAE, RMSE, dan MAPE secara otomatis. Melalui proses evaluasi ini, peneliti dapat menilai tingkat akurasi model, menentukan parameter terbaik, serta membandingkan hasil prediksi antar model, misalnya antara *Prophet* dan *Prophet* dengan *Bayesian Optimization*.

### 2.8 Indeks Harga Saham Gabungan (IHSG)

Indeks Harga Saham Gabungan (IHSG) merupakan indikator utama yang mencerminkan pergerakan seluruh harga saham di Bursa Efek Indonesia. IHSG digunakan sebagai tolok ukur kinerja pasar saham dan cerminan kondisi ekonomi nasional (Otoritas Jasa Keuangan, 2024). Perubahan nilai IHSG dipengaruhi oleh faktor internal seperti kinerja emiten, kebijakan pemerintah, dan kondisi makroekonomi, serta faktor eksternal seperti harga komoditas global dan kebijakan moneter negara maju.

Peramalan IHSG menjadi penting karena membantu investor dalam menentukan strategi investasi dan mengelola risiko pasar. Namun, sifat IHSG yang sangat fluktuatif dan dipengaruhi banyak variabel menjadikannya tantangan bagi model prediksi konvensional. Oleh karena itu, penerapan model *Prophet* dengan optimisasi Bayesian menjadi alternatif yang menjanjikan untuk menghasilkan prediksi yang lebih akurat dan adaptif terhadap dinamika pasar Indonesia.

## **BAB III**

### **METODE PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

Penelitian ini dilaksanakan pada semester ganjil tahun ajaran 2024/2025 bertempat Di Jurusan Matematika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Lampung.

#### **3.2 Data Penelitian**

Data yang digunakan berupa data historis Indeks Harga Saham Gabungan (IHSG) periode 1 Januari 2020 sampai 30 Desember 2025 (1449 Data) yang diperoleh melalui situs Investing Indonesia (<https://id.investing.com/>). Indeks Harga Saham Gabungan dinyatakan dalam satuan Rupiah (RP). Data terdiri dari dua kolom yaitu tanggal ( $ds/x$ ) dan harga penutupan ( $y$ ).

#### **3.3 Metode Penelitian**

Pada penelitian ini dilakukan analisis kinerja *hyperparameter tuning Bayesian Optimization* (BO) dalam model *Prophet* untuk meramalkan Indeks Harga Saham Gabungan (IHSG) dengan bantuan bahasa pemrograman *R*. Tahapan penelitian disusun secara sistematis, dengan langkah-langkah yang dilakukan sebagai berikut:

##### *1. Preprocessing Data*

Tahap *preprocessing* data dilakukan untuk memastikan kualitas dan konsistensi data sebelum digunakan dalam proses pemodelan. Data deret waktu terlebih dahulu diperiksa terhadap kemungkinan adanya nilai hilang (*missing values*),

duplikasi, maupun anomali ekstrem (*outliers*). Apabila ditemukan nilai hilang, penanganan dilakukan melalui metode interpolasi atau penghapusan observasi tertentu sesuai karakteristik data.

Selain itu, format data disesuaikan dengan kebutuhan model *Prophet*, yaitu terdiri atas dua kolom utama: ds (tanggal/waktu) dan y (nilai observasi). Proses ini bertujuan untuk menjaga integritas struktur kronologis data dan menghindari distorsi dalam proses pelatihan model (Hyndman & Athanasopoulos, 2021). Tahapan praproses yang sistematis sangat penting dalam analisis deret waktu karena kualitas data secara langsung memengaruhi performa model peramalan (Box *et al.*, 2016).

## 2. Analisis Deskriptif Data

Analisis deskriptif dilakukan untuk memberikan gambaran umum mengenai karakteristik data sebelum dilakukan pemodelan. Analisis ini meliputi perhitungan nilai minimum, maksimum, rata-rata (*mean*), standar deviasi, serta visualisasi data dalam bentuk grafik deret waktu (*time series plot*).

Tujuan analisis deskriptif adalah mengidentifikasi pola dasar seperti tren jangka panjang, pola musiman, serta fluktuasi acak yang terdapat dalam data (Chatfield, 2019). Informasi ini menjadi landasan dalam pemilihan pendekatan model yang sesuai dan dalam menentukan konfigurasi awal parameter model peramalan.

## 3. Pembagian Data *Train-Test*

Dalam penelitian ini, data dibagi menjadi dua bagian, yaitu 80% sebagai data pelatihan (*training set*) dan 20% sebagai data pengujian (*testing set*). Pembagian dilakukan berdasarkan urutan waktu, bukan secara acak, guna menjaga struktur kronologis data deret waktu.

Pendekatan ini bertujuan untuk menghindari data *leakage*, yaitu kondisi informasi masa depan secara tidak sengaja digunakan dalam proses pelatihan model (Hyndman & Athanasopoulos, 2021). Pembagian berbasis waktu merupakan praktik yang umum dan dianjurkan dalam studi peramalan deret waktu.

#### 4. Pembangunan Model *Prophet Baseline*

Model *Prophet baseline* dibangun menggunakan parameter *default* sebagaimana direkomendasikan dalam dokumentasi resmi dan literatur aslinya. *Prophet* merupakan model berbasis *additive regression* yang memodelkan data sebagai kombinasi komponen tren, musiman, dan efek peristiwa khusus (Taylor & Letham, 2018).

Model *baseline* ini berfungsi sebagai acuan awal untuk mengukur performa sebelum dilakukan optimisasi parameter lebih lanjut. Penggunaan model *baseline* penting dalam penelitian komparatif untuk memastikan adanya pembandingan yang objektif.

#### 5. Pembangunan Model *Prophet Baseline* dengan *Bayesian Optimization*

Untuk meningkatkan performa model, dilakukan optimisasi hiperparameter menggunakan pendekatan *Bayesian Optimization*. Metode ini bekerja dengan membangun model probabilistik untuk mengeksplorasi ruang parameter secara efisien, sehingga mampu menemukan kombinasi parameter terbaik tanpa melakukan pencarian menyeluruh seperti *grid search* (Snoek *et al.*, 2012).

Parameter yang dioptimasi meliputi *changepoint prior scale*, *seasonality prior scale*, dan parameter lain yang memengaruhi fleksibilitas model. *Bayesian Optimization* dinilai lebih efisien dan adaptif dalam proses pencarian hiperparameter dibandingkan metode konvensional. Berikut adalah parameter-parameter yang akan dioptimisasi.

Tabel 2. *Hyperparameter search space*

<i>Hyperparameter</i>	<i>Range</i>
<i>changepoint prior scale</i>	[0,01, 1,5]
<i>seasonality prior scale</i>	[0,1, 10]
<i>changepoint range</i>	[0,7, 0,95]

## 6. Pelatihan Model

Model dilatih menggunakan data pelatihan dengan konfigurasi parameter yang telah ditentukan. Pada model *baseline*, digunakan parameter *default*, sedangkan pada model kedua digunakan parameter hasil optimisasi *Bayesian*.

Proses pelatihan bertujuan untuk mengestimasi parameter model yang mampu meminimalkan kesalahan prediksi pada data historis (Taylor & Letham, 2018). Kinerja model selama pelatihan dipantau untuk memastikan konvergensi yang stabil.

## 7. Evaluasi Model

Evaluasi kinerja model dilakukan menggunakan metrik kesalahan peramalan, yaitu:

- *Root Mean Squared Error* (RMSE)
- *Mean Absolute Percentage Error* (MAPE)
- *Mean Absolute Error* (MAE)

RMSE digunakan untuk mengukur deviasi kuadrat rata-rata antara nilai aktual dan prediksi, sedangkan MAPE mengukur persentase kesalahan relatif terhadap nilai aktual (Hyndman & Koehler, 2006). Nilai RMSE dan MAPE yang lebih rendah menunjukkan performa model yang lebih baik dalam memprediksi data uji.

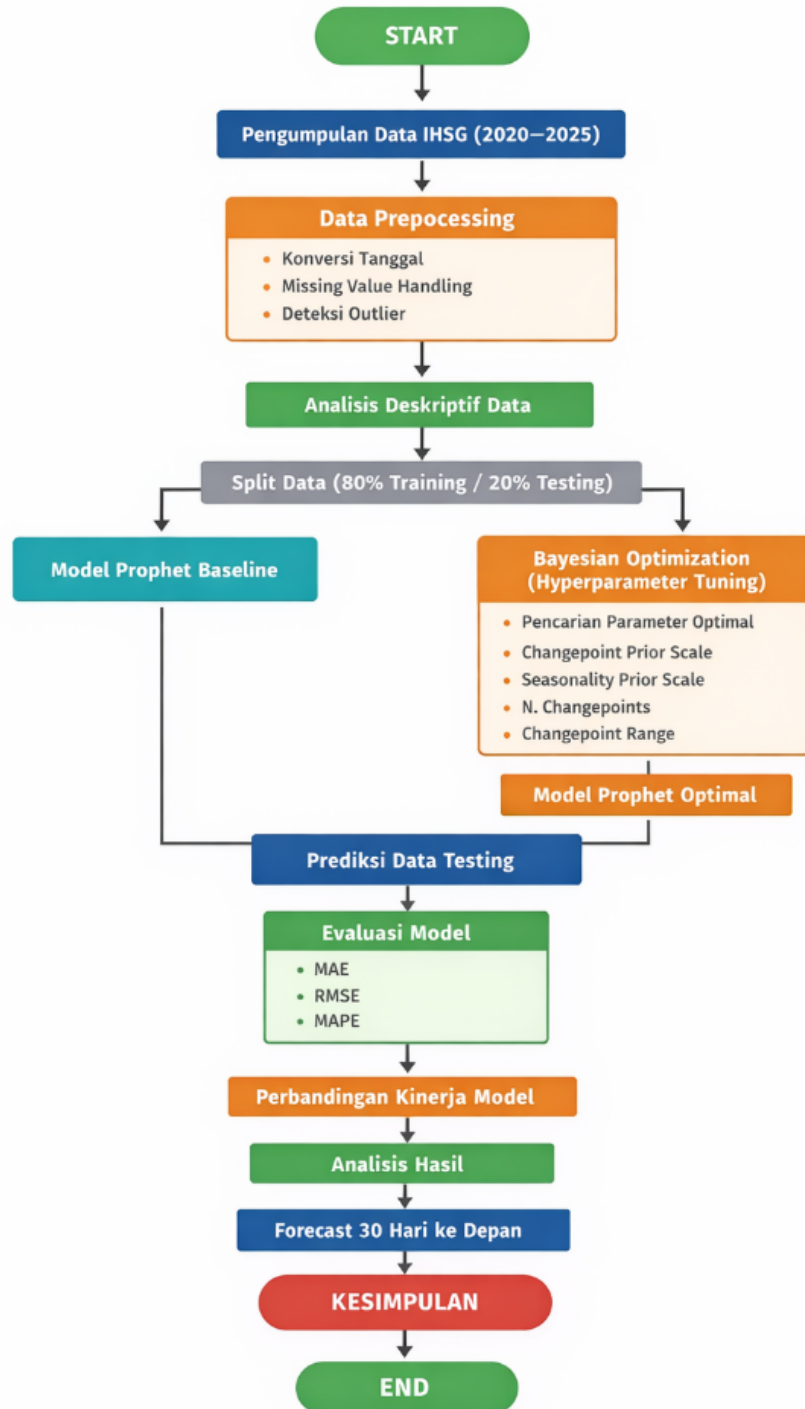
## 8. Perbandingan Model

Tahap ini dilakukan untuk membandingkan performa antara model *Prophet baseline* dan *Prophet* dengan *Bayesian Optimization*. Perbandingan dilakukan berdasarkan nilai RMSE dan MAPE pada data pengujian. Model dengan nilai kesalahan terendah dianggap memiliki kemampuan generalisasi yang lebih baik dan lebih sesuai untuk digunakan dalam peramalan data yang bersifat volatil dan kompleks.

## 9. Pelatihan Model *Final* dan *Forecasting*

Setelah model terbaik ditentukan berdasarkan hasil evaluasi, model tersebut dilatih kembali menggunakan seluruh dataset (*training + testing*) untuk membangun model *final*. Model *final* kemudian digunakan untuk menghasilkan prediksi atau *forecast* pada periode mendatang. Pendekatan ini bertujuan untuk memanfaatkan seluruh informasi historis yang tersedia sehingga menghasilkan estimasi yang lebih optimal (Box *et al.*, 2016).

**Alur Penelitian: Analisis Kinerja Metode Hyperparameter Tuning Bayesian Optimization pada Model Prophet untuk Prediksi IHSG**



Gambar 1. Flowchart Alur Penelitian

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan hasil dan pembahasan bisa disimpulkan bahwa:

1. Model *Prophet Baseline* mampu melakukan pemodelan trend jangka panjang IHSG, namun performanya masih terbatas karena penggunaan parameter bawaan yang kurang sesuai dengan karakteristik data pasar saham yang cenderung fluktuatif dan memiliki perubahan tren mendadak.
2. Penerapan Model *Prophet Baseline* menghasilkan nilai RMSE dan MAPE yang lebih besar dibandingkan oleh *Hyperparameter Tuning Model Prophet Baseline*. Dengan demikian, dapat disimpulkan bahwa penerapan *hyperparameter tuning* memberikan kontribusi positif terhadap peningkatan performa model *Prophet*.
3. Model *Prophet* dengan *Bayesian Optimization* menunjukkan pola yang lebih adaptif terhadap perubahan tren. Model ini lebih mengikuti arah pergerakan aktual terutama pada fase transisi dari penurunan menuju kenaikan

## DAFTAR PUSTAKA

- Acerbi, L., & Ma, W. J. (2017). Practical Bayesian optimization for model fitting with Bayesian adaptive direct search. *Advances in Neural Information Processing Systems*, **30**, 1837–1847.
- Alfoin, G., & Herawati, R. (2024). Comparison of weighted moving average and Prophet method in predicting stock prices. *Jurnal Informatika*, **3**(2): 85-94
- Armstrong, J. S. (2001). *Principles of Forecasting: A handbook for researchers and practitioners*. International Journal of Forecasting, **17**(4), 667-668.
- Armstrong, J. S., & Collopy, F. (1992). *Error measures for generalizing about forecasting methods: Empirical comparisons*. International Journal of Forecasting, **8**(1), 69–80.
- Bou-Ammar, H., & Osborne, M. (2023). Recent advances in Bayesian optimization for modern machine learning. *Journal of Artificial Intelligence Research*, **76**, 1123–1156.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley & Sons.
- Chatfield, C. (2019). *The Analysis of Time Series: An Introduction* (7th ed.). CRC Press.
- Chai, T., & Draxler, R. R. (2014). *Root mean square error (RMSE) or mean absolute error (MAE)*. Geoscientific Model Development, **7**(3), 1247–1250.
- Cowen-Rivers, A., Ostrovski, G., Marinier, R., Elsayed, G. F., Ciosek, K., Wang, Z., & Hutter, F. (2020). An empirical study of batch Bayesian optimization. *Advances in Neural Information Processing Systems*, **33**, 18361–18372.
- Eriksson, D., Pearce, M., Gardner, J., Turner, R. D., & Poloczek, M. (2019). Scalable global optimization via local Bayesian optimization (TuRBO). *Advances in Neural Information Processing Systems*, **32**, 5496–5507

- Gujarati, D. N., & Porter, D. C. (2020). *Basic Econometrics* (6th ed.). McGraw-Hill Education.
- Hamdani, A. F., Swanjaya, D., & Helilintar, R. (2023). Facebook Prophet model with Bayesian optimization for USH index prediction. *Jurnal Informatika*, **11**(2): 115-124
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, **22**(4), 679–688.
- Klein, A., Falkner, S., Bartels, S., Hennig, P., & Hutter, F. (2017). Fast Bayesian optimization of machine learning hyperparameters on large datasets. *Advances in Neural Information Processing Systems*, **30**, 393–402.
- Letham, B., & Taylor, S. J. (2017). Forecasting at Scale. *The American Statistician*, **72**(1): 37–45.
- Li, Y., Xiong, H., & Zhou, X. (2021). A hybrid forecasting model based on Prophet and machine learning methods for time series prediction. *Applied Sciences*, **11**(14), 6429.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (2019). *Forecasting: Methods and Applications* (4th ed.). John Wiley & Sons.
- Nurhasanah, D., Sari, R., & Pratama, A. (2023). Comparative Analysis of ARIMA and Prophet Models for IHSG Prediction. *Jurnal Sistem Informasi dan Komputer*, **12**(2): 112–120.
- Papacharalampous, G., & Tyrallis, H. (2018). Evaluation of Prophet Forecasting Model for Water Resource Time Series. *Environmental Modelling & Software*, **105**, 180–200.
- Rachmawati, D., & Kurniawan, A. (2022). Penerapan Model Facebook Prophet untuk Peramalan Harga Saham Sektor Keuangan di Indonesia. *Jurnal Teknologi dan Sistem Informasi Bisnis*, **4**(1): 25–36.
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian Optimization of Machine Learning Algorithms. *Advances in Neural Information Processing Systems* (NeurIPS 25).

- Springenberg, J. T., Klein, A., Falkner, S., & Hutter, F. (2016). Bayesian optimization with robust Bayesian neural networks. *Advances in Neural Information Processing Systems*, 29, 4134–4142.
- Taylor, S. J., & Letham, B. (2018). Prophet: Forecasting at Scale. *The American Statistician*, 72(1): 37–45.
- Triebe, O., Hewamalage, H., Pilyugina, P., Laptev, N., Bergmeir, C., & Rajagopal, R. (2021). NeuralProphet: Explainable forecasting at scale.
- Tsay, R.S. (2010). *Analysis of Financial Time Series* (3rd ed). Wiley, New York.
- Ying, J., Kuo, L., & Seow, G. (2005). Forecasting stock prices using a hierarchical Bayesian approach. *Journal of Forecasting*, 24(1): 39-59
- Zhang, G.P. (2003). *Time Series Forecasting using a hybrid ARIMA and neural network model*. *Neucomputing*, 50, 159-175.
- Zhang, Y., & Luo, C. (2021). Enhancing Prophet Model Performance Using Bayesian Optimization for Energy Consumption Forecasting. *Energy Reports*, 7, 3549–3560.
- Zhang, Z., & Wang, P. (2020). Stock Price Prediction with Time Series Forecasting Models: A Comparative Study. *Procedia Computer Science*, 177, 107–113.