

BAB I

PENDAHULUAN

1.1 Latar Belakang

Inflasi bulanan Indonesia menunjukkan dinamika yang berubah cukup signifikan dalam beberapa tahun terakhir. Badan Pusat Statistik mencatat tingkat inflasi Indonesia sebesar 1,87% pada tahun 2021 dan meningkat menjadi 5,51% pada tahun 2022 akibat kenaikan harga energi dan pangan global. Inflasi kemudian menurun menjadi 2,61% pada tahun 2023 dan bergerak pada kisaran 2% hingga 3% selama tahun 2024 hingga awal tahun 2025. Perubahan tersebut menunjukkan bahwa pergerakan inflasi Indonesia tidak selalu mengikuti pola yang stabil karena berbagai faktor seperti perubahan harga komoditas, kebijakan pemerintah, serta kondisi ekonomi global. Kondisi tersebut membuat pemerintah dan otoritas moneter memerlukan perkiraan inflasi yang akurat agar kebijakan ekonomi dapat disusun secara tepat (Badan Pusat Statistik, 2024). Ahmar & Fitmayanti (2021) menyatakan bahwa peramalan inflasi perlu dilakukan agar pemerintah dapat memprediksi tingkat inflasi secara tepat sehingga dapat mendukung tercapainya pertumbuhan ekonomi yang berkelanjutan.

Model peramalan menjadi bagian penting dalam analisis data ekonomi karena model tersebut memanfaatkan pola historis data untuk memperkirakan nilai pada periode berikutnya. Hyndman & Athanasopoulos (2021) menyatakan bahwa data deret waktu (*time series*) dapat mengandung pola seperti tren, musiman, dan fluktuasi lainnya yang perlu diidentifikasi sebelum menentukan metode peramalan yang sesuai. Pola data tersebut memungkinkan peneliti membangun model peramalan yang mampu menghasilkan prediksi yang lebih akurat. Perkembangan

analisis data mendorong penggunaan berbagai metode statistik maupun metode *machine learning* dalam kegiatan peramalan. Berbagai peneliti menggunakan metode yang berbeda untuk menyesuaikan karakteristik pola data yang dianalisis. Penggunaan perbedaan metode tersebut menghasilkan tingkat akurasi prediksi yang juga berbeda.

Penelitian mengenai peramalan inflasi telah berkembang dengan memanfaatkan berbagai pendekatan statistik maupun machine learning. Iqbal & Satti (2023) membandingkan model *Naive*, ARIMA, *Phillips Curve*, dan *Phillips Curve Threshold Autoregressive* (PC-TAR) untuk memprediksi inflasi di Pakistan menggunakan data periode 1974–2016. Hasil penelitian menunjukkan bahwa model *Naive* menghasilkan kinerja peramalan terbaik pada sebagian besar skenario pengujian berdasarkan nilai RMSE dan MAE yang lebih rendah dibandingkan model lainnya. Hasil penelitian tersebut menunjukkan bahwa model statistik konvensional masih memiliki kemampuan yang baik dalam menghasilkan prediksi inflasi. Karakteristik model statistik konvensional yang mengandalkan pola historis data dan hubungan yang relatif sederhana menyebabkan kemampuan model dalam menangkap pola yang kompleks serta perubahan hubungan antarvariabel menjadi terbatas. Seiring berkembangnya teknologi analisis data, pendekatan machine learning mulai digunakan untuk mengatasi keterbatasan model statistik konvensional dalam memodelkan fenomena ekonomi yang kompleks. Salah satu penelitian yang menerapkan pendekatan tersebut dilakukan oleh Sumarminingsih *et al.* (2025) yang menggunakan metode *Long Short-Term Memory* (LSTM) untuk memodelkan inflasi di Indonesia dengan melibatkan berbagai faktor ekonomi, seperti nilai tukar, suku bunga, harga minyak dunia, indikator kebijakan

pemerintah, serta faktor musiman. Hasil penelitian menunjukkan bahwa LSTM mampu menghasilkan prediksi yang akurat melalui kemampuannya dalam mempelajari hubungan nonlinier antarvariabel. Kompleksitas struktur model dan banyaknya variabel input yang digunakan menyebabkan proses pemodelan menjadi lebih rumit dibandingkan pendekatan statistik konvensional. Perbedaan karakteristik tersebut menunjukkan bahwa setiap metode memiliki kelebihan dan keterbatasan dalam memprediksi inflasi. Penelitian ini dilakukan untuk membandingkan kinerja berbagai metode peramalan sehingga dapat diperoleh model yang paling sesuai dengan karakteristik data inflasi yang digunakan.

Metode peramalan terus mengalami perkembangan seiring dengan semakin kompleksnya pola data ekonomi. Banyak data ekonomi menunjukkan pola tren dan musiman yang berubah dari waktu ke waktu sehingga peneliti memerlukan model yang lebih fleksibel untuk menganalisis data tersebut. Kondisi ini mendorong munculnya berbagai pendekatan peramalan baru yang dirancang khusus untuk menangani data deret waktu. Salah satu metode peramalan yang berkembang dalam analisis data deret waktu adalah metode *Prophet*. Metode *Prophet* dikembangkan di perusahaan teknologi Meta sebagai model regresi aditif untuk menganalisis data deret waktu dengan memisahkan komponen tren, musiman, dan kejadian khusus dalam suatu rangkaian data. Struktur model tersebut membantu peneliti mengamati perubahan tren yang tidak linier serta pola musiman yang berulang secara lebih jelas. Kemampuan tersebut membuat metode *Prophet* lebih fleksibel dalam menyesuaikan diri dengan dinamika data dibandingkan model deret waktu klasik (Taylor & Letham, 2018). Saeed *et al.* (2023) menerapkan model *Prophet* dengan dan tanpa penambahan variabel regressor untuk memprediksi tarif angkutan

kontainer internasional menggunakan data periode 2010–2020. Kinerja model dievaluasi menggunakan *Mean Absolute Error* (MAE). Hasil penelitian menunjukkan bahwa model *Prophet* yang dilengkapi variabel regressor menghasilkan akurasi prediksi yang lebih baik dibandingkan model *Prophet* tanpa regressor. Shakeel *et al.* (2023) membandingkan *FB-Prophet* dengan beberapa metode *machine learning* dan *deep learning* dalam memprediksi beban energi pada jaringan pemanas distrik menggunakan metrik evaluasi MAE, RMSE, dan R^2 . Hasil penelitian menunjukkan bahwa *FB-Prophet* mampu menghasilkan kinerja yang kompetitif dalam menangkap pola permintaan energi yang dipengaruhi oleh tren dan musiman, sehingga menunjukkan bahwa metode tersebut tetap efektif meskipun dihadapkan pada model yang lebih kompleks. Cheng *et al.* (2024) membandingkan metode SARIMA, *FB-Prophet*, dan *Long Short-Term Memory* (LSTM) dalam memprediksi harga Bitcoin menggunakan data periode 2017–2022 dengan evaluasi berupa *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Root Mean Square Error* (RMSE). Hasil penelitian menunjukkan bahwa setiap metode menghasilkan tingkat akurasi yang berbeda sesuai dengan karakteristik data yang digunakan, sedangkan *FB-Prophet* tetap mampu memberikan hasil prediksi yang baik pada data deret waktu yang memiliki pola tren dan musiman. Ketiga penelitian tersebut menunjukkan bahwa metode *Prophet* mampu menghasilkan kinerja peramalan yang baik pada berbagai sektor, seperti transportasi, energi, dan aset digital. Penerapan metode *Prophet* pada peramalan inflasi masih relatif terbatas sehingga penelitian ini dilakukan untuk mengevaluasi efektivitas metode tersebut dalam memprediksi inflasi.

Metode *Prophet* memiliki kemampuan yang baik dalam memodelkan data deret waktu, namun performa model dipengaruhi oleh konfigurasi *hyperparameter* yang digunakan. *Hyperparameter* merupakan parameter yang nilainya ditentukan sebelum proses pelatihan model dan tidak dipelajari secara langsung dari data. Pemilihan konfigurasi *hyperparameter* yang tepat dapat meningkatkan kemampuan model dalam menangkap pola data dan menghasilkan prediksi yang lebih akurat. Proses pencarian konfigurasi tersebut dikenal sebagai *hyperparameter optimization* yang bertujuan memperoleh performa model yang optimal (Feurer & Hutter, 2019). Bergstra & Bengio (2012) membahas optimasi *hyperparameter* pada model *machine learning* dengan membandingkan berbagai strategi pencarian parameter. Penelitian tersebut menunjukkan bahwa proses optimasi *hyperparameter* berperan penting dalam meningkatkan performa model melalui pemilihan konfigurasi parameter yang lebih sesuai dengan karakteristik data. Probst *et al.* (2019) mengkaji pengaruh *hyperparameter* terhadap performa model *Random Forest* menggunakan teknik *Sequential Model-Based Optimization* (SMBO). Hasil penelitian menunjukkan bahwa proses tuning *hyperparameter* mampu meningkatkan kualitas prediksi dibandingkan penggunaan parameter default sehingga konfigurasi *hyperparameter* menjadi faktor penting dalam pengembangan model *machine learning*. Akbar *et al.* (2025) memprediksi harga minyak mentah Brent menggunakan data harian periode 2018–2024 dengan model *Prophet* yang dioptimasi menggunakan *Tree-Structured Parzen Estimator* (TPE) dengan evaluasi menggunakan metrik MAE, RMSE, dan MAPE dan menunjukkan bahwa model *Prophet*-TPE menghasilkan performa yang lebih baik dibandingkan *Prophet* tanpa optimasi maupun beberapa model peramalan lainnya. Aulia *et al.* (2025)

memprediksi harga emas Antam menggunakan 4.546 data harian periode 2014–2024 dengan model *Prophet* yang dioptimasi menggunakan *Bat Algorithm* dengan evaluasi menggunakan metrik RMSE dan MAPE menunjukkan bahwa proses optimasi mampu meningkatkan akurasi prediksi secara signifikan dibandingkan model *Prophet* dengan konfigurasi awal. Temuan dari keempat penelitian terdahulu menunjukkan bahwa optimasi *hyperparameter* memiliki peran penting dalam meningkatkan performa model prediksi. Berbagai teknik optimasi seperti SMBO, TPE, dan *Bat Algorithm* telah digunakan untuk memperoleh konfigurasi parameter yang lebih optimal. Pemanfaatan *Grid Search* untuk optimasi *hyperparameter* pada model *Prophet* masih relatif terbatas, khususnya pada peramalan inflasi, sehingga efektivitas metode tersebut dalam meningkatkan akurasi prediksi masih perlu dievaluasi lebih lanjut.

Keterbatasan penelitian mengenai penggunaan *Grid Search* untuk optimasi *hyperparameter* pada model *Prophet* dalam peramalan inflasi menunjukkan adanya peluang penelitian yang masih dapat dikembangkan, sehingga Penelitian ini menggunakan data inflasi bulanan Indonesia periode Januari 2000–Desember 2025 untuk membangun model *Prophet* yang dioptimasi menggunakan *Grid Search* dan menghasilkan peramalan inflasi periode Januari–Desember 2026. Hasil penelitian diharapkan dapat memberikan bukti empiris mengenai efektivitas optimasi *hyperparameter* dalam meningkatkan akurasi peramalan inflasi menggunakan metode *Prophet*.

1.2 Rumusan Masalah

Permasalahan yang telah diuraikan pada latar belakang penelitian dirumuskan ke dalam beberapa pertanyaan penelitian sebagai berikut:

1. Bagaimana karakteristik dinamika inflasi bulanan Indonesia berdasarkan data historis periode Januari 2000 hingga Desember 2025?
2. Bagaimana kinerja metode *Prophet* dalam meramalkan inflasi bulanan Indonesia 12 bulan ke depan sebelum dan setelah dilakukan optimasi *hyperparameter* berdasarkan nilai MAE dan RMSE?
3. Bagaimana efektivitas optimasi *hyperparameter* menggunakan metode *Grid Search* dalam meningkatkan akurasi model *Prophet*?

1.3 Tujuan Penelitian

Penelitian ini menetapkan beberapa tujuan yang sesuai dengan rumusan masalah penelitian sebagai berikut:

1. Menganalisis dinamika inflasi bulanan Indonesia berdasarkan data historis periode Januari 2000 hingga Desember 2025 untuk memperoleh gambaran karakteristik dan pola pergerakan inflasi yang menjadi dasar dalam proses peramalan.
2. Menganalisis kinerja metode *Prophet* dalam meramalkan inflasi bulanan Indonesia 12 bulan ke depan sebelum dan setelah dilakukan optimasi *hyperparameter* berdasarkan nilai MAE dan RMSE.
3. Menganalisis efektivitas optimasi *hyperparameter* menggunakan metode *Grid Search* dalam meningkatkan akurasi model *Prophet*.

1.4 Batasan Masalah

Penelitian ini menetapkan batasan masalah agar ruang lingkup penelitian tetap terfokus dan sesuai dengan tujuan penelitian. Batasan masalah yang digunakan meliputi:

1. Penelitian ini difokuskan pada penggunaan metode *Prophet* dalam memodelkan dan meramalkan inflasi bulanan Indonesia, khususnya untuk menganalisis kemampuan model dalam menangkap fluktuasi data, termasuk fluktuasi ekstrem, baik sebelum maupun setelah dilakukan pengaturan parameter.
2. Analisis dilakukan menggunakan pendekatan deret waktu (*time series*) yang hanya memanfaatkan data historis inflasi, tanpa membahas hubungan kausal atau faktor-faktor penyebab terjadinya inflasi.
3. Model yang dibangun tidak memasukkan variabel eksternal maupun komponen tambahan seperti efek kejadian khusus (*holiday effect*), shock ekonomi, atau variabel regresor tambahan lainnya.
4. Penelitian ini tidak melakukan perbandingan dengan metode peramalan lain maupun teknik optimasi *hyperparameter* selain *Grid Search*.
5. Rentang nilai *hyperparameter* dalam proses optimasi *Grid Search* dibatasi dan disesuaikan dengan karakteristik data inflasi yang digunakan, sehingga tidak mencakup seluruh kemungkinan kombinasi parameter secara menyeluruh.