

PERBANDINGAN METODE HOLT-WINTERS ADITIF DAN MULTIPLIKATIF DENGAN OPTIMASI GENETIC ALGORITHM PADA PERAMALAN PRODUKSI KOPI INDONESIA TAHUN 2023

Syahza Mahza

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Hasanuddin
syhamahza@gmail.com

Sitti Sahrman

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Hasanuddin
Sittisahrimansalam@gmail.com*

Abstrak

Produksi kopi Indonesia menunjukkan pola musiman yang dipengaruhi kondisi iklim sehingga fluktuasinya cukup besar setiap tahun. Ketidakpastian ini menuntut metode peramalan yang akurat untuk mendukung pengambilan keputusan terkait produksi dan distribusi. Metode Triple Exponential Smoothing Holt-Winters mampu menangkap pola tren dan musiman, tetapi penentuan parameter pemulusannya sering dilakukan secara trial and error sehingga akurasi kurang optimal. Tujuan. Penelitian ini bertujuan memperoleh parameter optimal α , β , dan γ menggunakan Genetic Algorithm (GA) serta membandingkan performa pendekatan aditif dan multiplikatif untuk menentukan metode yang paling sesuai dalam peramalan produksi kopi Indonesia. Metode. Data produksi kopi Indonesia periode 2016–2023 dari Badan Pusat Statistik (BPS) dianalisis menggunakan Holt-Winters aditif dan multiplikatif, kemudian parameter pemulusan dioptimasi menggunakan Genetic Algorithm untuk meningkatkan akurasi. Hasil. Identifikasi pola menunjukkan bahwa data memiliki karakter musiman multiplikatif. Sebelum optimasi, pendekatan multiplikatif menghasilkan MAPE sebesar 62,23% (korelasi 0,9740), lebih baik dibandingkan aditif dengan MAPE 95,00%. Setelah optimasi GA, diperoleh parameter terbaik α 0,0230; β 0,2851; dan γ 0,9175, yang menurunkan MAPE pendekatan multiplikatif menjadi 0,5024% dan aditif menjadi 12,2092%, dengan korelasi keduanya mencapai 0,9997. Kesimpulan. Pendekatan multiplikatif Holt-Winters merupakan metode yang paling sesuai untuk pola musiman produksi kopi Indonesia. Optimasi Genetic Algorithm terbukti mampu meningkatkan akurasi peramalan secara signifikan pada kedua pendekatan, dengan performa terbaik ditunjukkan oleh Holt-Winters multiplikatif hasil optimasi.

Kata Kunci: *Holt-Winters, Genetic Algorithm, peramalan, produksi kopi, optimasi parameter.*

Abstract

Coffee is one of the leading plantation commodities in Indonesia. Its production exhibits a strong seasonal pattern influenced by climatic factors, resulting in substantial fluctuations from year to year. This uncertainty creates a need for accurate forecasting methods to support decision-making in production and distribution. The Triple Exponential Smoothing Holt-Winters method is capable of capturing trend and seasonal components; however, its smoothing parameters are often determined through trial and error, which may lead to suboptimal accuracy. To address this issue, an optimization approach based on the Genetic Algorithm (GA) is employed to obtain more precise and efficient parameter estimates. Objective. To obtain the optimal smoothing parameters α , β , and γ using the Genetic Algorithm and to determine whether the additive or multiplicative Holt-Winters approach performs better for forecasting Indonesia's coffee production. Methods. The study used monthly Indonesian coffee production data from 2016–2023 sourced from Statistics Indonesia (BPS). Holt-Winters forecasting was evaluated using both additive and multiplicative forms, followed by parameter optimization using the Genetic Algorithm. Results. The multiplicative approach reflected the seasonal pattern more accurately, yielding an initial MAPE of 62.23% with a correlation of 0.9740. After optimization, the GA produced optimal parameters $\alpha = 0.0230$, $\beta = 0.2851$, and $\gamma = 0.9175$. These parameters significantly improved model performance, reducing MAPE to 0.5024% and increasing correlation to 0.9997, indicating highly precise forecasting results. Conclusion. The multiplicative Holt-Winters method optimized with the Genetic Algorithm is the most appropriate and accurate approach for modeling Indonesia's coffee production pattern.

Keywords: *Holt-Winters, Genetic Algorithm, coffee production forecasting, time series, parameter optimization.*

PENDAHULUAN

Indonesia merupakan negara dengan basis agraris yang perekonomiannya bergantung pada sektor pertanian. Pada tahun 2023, sektor pertanian, kehutanan, dan perikanan berkontribusi sebesar 12,53% terhadap Produk Domestik Bruto (PDB) nasional, menjadikannya sebagai sektor penyumbang ketiga terbesar setelah industri pengolahan dan perdagangan. Salah satu subsektor penting adalah perkebunan, dengan kontribusi sebesar 3,88% terhadap total PDB dan 30,99% terhadap PDB sektor pertanian (Badan Pusat Statistik, 2024). Komoditas kopi menjadi unggulan karena berperan sebagai sumber devisa, pendapatan petani, bahan baku industri, serta penyedia lapangan kerja (Nasirudin et al., 2022). Produksi kopi Indonesia didominasi oleh kopi robusta (72,71%) dan sebagian besar dihasilkan oleh perkebunan rakyat (95,75%) (Kemenpri., 2023).

Produksi kopi memiliki pola musiman yang dipengaruhi oleh iklim dan cuaca. Musim panen utama terjadi pada Mei-September, sedangkan variabilitas iklim seperti El Niño dan La Niña dapat menurunkan produktivitas (Ramadhillah & Masjud, 2024). Indonesia menempati posisi kedua produsen kopi terbesar di Asia-Oseania setelah Vietnam, dengan produksi mencapai 12 juta karung pada 2022/2023 (International Coffee Organization, 2023). Meskipun demikian, produksi kopi berfluktuasi akibat faktor iklim, hama, dan dinamika pasar yang menimbulkan ketidakpastian dalam perencanaan produksi dan distribusi. Oleh karena itu, diperlukan metode peramalan yang akurat untuk mendukung pengambilan keputusan dan menjaga stabilitas sektor perkebunan (Djazuli et al., 2024).

Peramalan merupakan proses memprediksi kondisi masa depan berdasarkan data historis melalui pendekatan kualitatif maupun kuantitatif (Rizal et al., 2021). Salah satu metode kuantitatif yang banyak digunakan adalah Exponential Smoothing, yang memiliki tiga varian utama: Single, Double, dan Triple Exponential Smoothing (Ilahi & Agustin, 2022). Triple Exponential Smoothing Holt-Winters mampu memodelkan komponen level, tren, dan musiman secara bersamaan, sehingga lebih sesuai untuk data dengan pola musiman (Puspita, 2022).

Namun, kelemahan utama metode ini adalah penentuan parameter pemulusan (α, β, γ) yang sering

dilakukan secara trial and error, sehingga hasilnya belum tentu optimal. Untuk mengatasinya, digunakan pendekatan optimasi berbasis Genetic Algorithm (GA), yang meniru proses evolusi melalui seleksi, crossover, dan mutasi guna mencari solusi terbaik (Sriwindono & Putranto, 2022). Berbagai penelitian, seperti Violina et al. (2025) dan Nufus & Sutarmanto (2022), menunjukkan bahwa penerapan GA dalam optimasi model peramalan mampu meningkatkan akurasi dan menurunkan tingkat kesalahan secara signifikan. Oleh karena itu, kombinasi metode Holt-Winters dan Genetic Algorithm menjadi pendekatan potensial untuk menghasilkan model peramalan produksi kopi yang lebih akurat dan efisien.

KAJIAN TEORI

Analisis Runtun Waktu

Analisis deret waktu merupakan metode statistik yang digunakan untuk menganalisis data yang dikumpulkan secara berurutan berdasarkan interval waktu tertentu, seperti harian, bulanan, atau tahunan (Prasetya et al., 2020). Tujuan utamanya adalah memahami struktur data, mengenali pola, serta meramalkan nilai masa depan berdasarkan data historis. Metode ini banyak diterapkan dalam bidang ekonomi, keuangan, meteorologi, dan produksi untuk mengidentifikasi tren, pola musiman, serta fluktuasi data (Admirani, 2018). Setiap observasi dalam deret waktu saling berkorelasi, sehingga pemilihan metode yang tepat harus disesuaikan dengan pola data yang akan diprediksi (Mardania et al., 2024; Lusiana & Yulianty, 2020).

Exponential Smoothing

Exponential Smoothing adalah salah satu metode dalam deret waktu yang menggunakan pembobotan eksponensial pada masa lalu (Aryati et al., 2020). Metode ini merupakan perkembangan dari metode moving average sederhana, yang bermula dengan rumus pada Persamaan 1 sebagai berikut (Aryati et al., 2020):

$$F_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-n+1}}{n}$$

$$F_{t+1} = \frac{Y_t}{n} + \frac{Y_{t-1}}{n} + \dots + \frac{Y_{t-n+1}}{n} \quad (1)$$

Selanjutnya, untuk mendapatkan bentuk umum rata-rata bergerak pada periode ke $-t$, digunakan Persamaan 2 berikut.

$$F_t = \frac{Y_{t-1} + Y_{t-2} + \dots + Y_{t-n}}{n}$$

$$F_t = \frac{Y_{t-1}}{n} + \frac{Y_{t-2}}{n} + \dots + \frac{Y_{t-n}}{n} \quad (2)$$

Dengan melihat hubungan pada persamaan 1 dan 2, jika nilai F_t sudah diketahui maka nilai $F_t + 1$ dapat dicari berdasarkan nilai F_t tersebut.

$$F_{t+1} = \frac{Y_t}{n} + F_t - \frac{Y_{t-n}}{n} \quad (3)$$

Jika mengganti $Y_t - n$ dengan nilai peramalan pada tahun ke- t (yaitu F_t), maka persamaan 3 berubah menjadi persamaan 4 sebagai berikut.

$$F_{t+1} = \frac{Y_t}{n} + F_t - \frac{F_t}{n} \quad (4)$$

Dapat dirubah lagi dengan persamaan 5 menjadi:

$$F_{t+1} = \frac{1}{n}Y_t + \left(1 - \frac{1}{n}\right)F_t \quad (5)$$

Di dalam metode *Exponential Smoothing* nilai n 1 diganti dengan α , sehingga rumus peramalannya seperti persamaan 6 sebagai berikut:

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (6)$$

dengan,

- Y_t : Nilai aktual data pada periode ke- t
- F_t : Nilai peramalan pada periode ke- t
- n : Jumlah data
- Y_{t-n} : Lama suatu pengamatan
- F_{t+1} : Nilai peramalan pada satu periode ke depan
- α : Konstanta pemulusan ($0 \leq \alpha \leq 1$)

Metode *Exponential Smoothing* dibedakan menjadi tiga jenis yaitu Single Exponential Smoothing (SES) yang digunakan pada runtun waktu yang tidak memiliki unsur tren maupun musiman atau dapat dikatakan data stasioner, hanya memerlukan satu parameter smoothing yaitu alpha (α); Double Exponential Smoothing (DES) digunakan untuk peramalan data runtun waktu yang mengandung unsur tren, memerlukan dua parameter smoothing yaitu alpha (α) dan beta (β); dan Triple Exponential Smoothing (TES) yang digunakan untuk meramalkan data runtun waktu yang memiliki unsur tren dan juga musiman dengan menggunakan tiga parameter smoothing yaitu alpha (α), beta (β), dan gamma (γ). Bentuk umum dari *Exponential Smoothing* ditunjukkan pada rumus sebagai berikut.

Triple Exponential Smoothing Holt-Winters

Metode *Triple Exponential Smoothing Holt-Winters* merupakan pengembangan dari metode *Exponential*

Smoothing yang memperhitungkan tiga komponen utama, yaitu level (S_t), tren (b_t), dan musiman (l_t), dengan parameter pemulusan α , β , dan γ (Andriani et al., 2022). Metode ini terdiri atas dua model, yakni aditif dan multiplikatif. Model aditif digunakan ketika fluktuasi tren dan pola musiman relatif konstan, sedangkan model multiplikatif digunakan ketika pola musiman berubah seiring waktu.

Proses inisialisasi dilakukan dengan menentukan nilai awal untuk komponen level, tren, dan musiman (Hyndman & Athanasopoulos, 2018). Nilai awal level diperoleh dari rata-rata data pada satu musim pertama, dengan rumus sebagai berikut.

$$S_t = \frac{1}{s}(Y_1 + Y_2 + \dots + Y_t) \quad (7)$$

Tren dihitung berdasarkan selisih rata-rata antarperiode, dengan rumus sebagai berikut.

$$b_t = \frac{1}{s} \left(\frac{Y_{s+1} - Y_1}{s} + \frac{Y_{s+2} - Y_2}{s} + \dots + \frac{Y_{s+t} - Y_t}{s} \right) \quad (8)$$

Sedangkan indeks musiman ditentukan melalui rasio antara data aktual dan nilai pemulusan. Untuk model aditif seperti pada rumus berikut.

$$l_1 = Y_1 - S_t, l_2 = Y_2 - S_t, \dots, l_t = Y_t - S_t \quad (9)$$

Untuk model multiplikatif seperti pada rumus berikut.

$$l_1 = \frac{Y_1}{S_t}, l_2 = \frac{Y_2}{S_t}, \dots, l_t = \frac{Y_t}{S_t} \quad (10)$$

Setelah inisialisasi awal, dilakukan proses implementasi pemulusan TES *Holt-Winters* pada model aditif ditunjukkan pada rumus sebagai berikut.

$$S_t = \alpha(Y_t - l_{t-s}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (11)$$

$$b_t = \beta(S_t - S_{t-s}) + (1 - \beta)b_{t-1} \quad (12)$$

$$l_t = \gamma(Y_t - S_t) + (1 - \gamma)l_{t-s} \quad (13)$$

$$F_{t+m} = S_t + b_t m + l_{t-s+m} \quad (14)$$

Implementasi pemulusan TES *Holt-Winters* pada model multiplikatif ditunjukkan pada rumus sebagai berikut.

$$S_t = \alpha \frac{Y_t}{l_{t-s}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (15)$$

$$b_t = \beta(S_t + S_{t-1}) + (1 - \beta)b_{t-1} \quad (16)$$

$$l_t = \gamma \frac{Y_t}{S_t} + (1 - \gamma)l_{t-s} \quad (17)$$

$$F_{t+m} = S_t + b_t m + l_{t-s+m} \quad (18)$$

Keterangan:

- Y_t : Data aktual pada periode ke- t
- S_t : Nilai awal pemulusan *level*
- b_t : Nilai awal pemulusan tren
- l_t : Nilai awal pemulusan musiman
- s : Panjang musiman
- t : Indeks waktu

- α : Konstanta pemulusan untuk S_t
- β : Konstanta pemulusan untuk b_t
- γ : Konstanta pemulusan untuk l_t
- l_{t-s} : Nilai pemulusan musiman $t - s$ pada periode t
- m : Panjang waktu peramalan
- F_{t+m} : Hasil peramalan pada periode $t + m$

Genetic Algorithm

Algoritma Genetika (*Genetic Algorithm*) pertama kali diperkenalkan oleh John Holland dari Universitas Michigan, Amerika Serikat, melalui bukunya *Adaptation in Natural and Artificial Systems* (1975). Metode ini dikembangkan berdasarkan prinsip evolusi biologis, terutama seleksi alam dan variasi genetik. Algoritma Genetika merupakan teknik pencarian dan optimasi yang digunakan untuk menemukan solusi terbaik dari ruang solusi yang luas dan kompleks. Prosesnya dilakukan dengan mengevaluasi sejumlah kandidat solusi, kemudian secara iteratif memilih dan memodifikasi solusi tersebut berdasarkan fungsi evaluasi yang disebut **fitness function**. Metode ini termasuk dalam kelompok algoritma evolusioner yang meniru mekanisme biologis seperti pewarisan sifat, seleksi alam, mutasi, dan rekombinasi (*crossover*). Selain itu, Algoritma Genetika juga digolongkan sebagai algoritma metaheuristik karena kemampuannya menyelesaikan permasalahan optimasi yang sulit dipecahkan secara konvensional (Mitchell, 1998).

Dekode Kromosom

Dekode kromosom merupakan proses mengubah representasi genetik dalam kromosom menjadi nilai-nilai yang merepresentasikan setiap variabel. Tahapan ini bertujuan untuk menghubungkan genotipe, yang berupa deretan bilangan biner dan digunakan dalam proses genetika seperti *crossover* serta mutasi, dengan fenotipe yang merupakan hasil interpretasi genotipe untuk menilai kualitas kromosom (Hakemi et al., 2023). Secara umum, pengkodean kromosom dapat dilakukan melalui beberapa skema, yaitu pengkodean bilangan real, pengkodean desimal diskrit, dan pengkodean biner. Secara umum, terdapat beberapa skema pengkodean kromosom yang digunakan, antara lain (Mujahid et al., 2022):

- a. Pengkodean Bilangan Real (Real Number Encoding), dalam skema ini, nilai gen berada

pada interval $\{y|0 < y < 1, y \in R(+)\}$, yang berarti nilai gen y berada di antara 0 dan 1, dengan Y merupakan elemen bilangan real positif.

- b. Pengkodean Desimal Diskrit (*Discrete Decimal Encoding*), pada skema ini, setiap gen memiliki nilai berupa bilangan bulat dalam rentang 0 hingga 9, yaitu $\{y|0 \leq y \leq 9, y \in Z\}$.
- c. Pengkodean Biner (*Binary Encoding*), dalam skema ini, setiap gen memiliki nilai berupa 1 atau 0.

Pembentukan Populasi Awal

Pembentukan populasi awal dilakukan dengan membangkitkan sejumlah individu secara acak atau berdasarkan prosedur tertentu. Ukuran populasi ditentukan sesuai kompleksitas permasalahan dan jenis operator genetika yang digunakan. Populasi awal ini berfungsi sebagai titik awal proses evolusi untuk menghasilkan berbagai solusi potensial dalam penyelesaian masalah optimasi (Simanjuntak et al., 2024)

Evaluasi Fitness

Evaluasi fitness merupakan tahap penilaian kualitas setiap kromosom dalam populasi berdasarkan fungsi tujuan yang telah ditetapkan. Nilai fitness mencerminkan tingkat kemampuan solusi dalam menyelesaikan permasalahan dan menjadi dasar seleksi pada generasi berikutnya (Harianto et al., 2025). Proses ini dilakukan dengan menghitung nilai fitness masing-masing individu hingga memenuhi kriteria penghentian. Jika tujuan optimasi adalah memaksimalkan fungsi, maka nilai fitness diambil langsung dari hasil perhitungan fungsi tersebut. Sebaliknya, pada tujuan minimisasi, nilai fitness dihitung melalui invers atau transformasi fungsi agar tetap sesuai dengan prinsip seleksi berdasarkan nilai maksimum (Simanjuntak et al., 2024).

Seleksi

Seleksi bertujuan memilih individu terbaik untuk menghasilkan keturunan dengan nilai fitness lebih tinggi pada generasi berikutnya (Mayyani et al., 2023). Metode yang umum digunakan adalah Roulette Wheel Selection (RWS), di mana peluang individu terpilih bergantung pada nilai fitness-nya (Cerf, 2017). Individu dengan fitness tinggi memiliki

probabilitas seleksi lebih besar dibandingkan yang rendah (Whardhana et al., 2024). Secara umum, rumus peluang pemilihan $P[i]$ untuk individu ke- i ditentukan menggunakan rumus sebagai berikut (Sriwindono & Putranto, 2022):

$$P[i] = \frac{f[i]}{\sum f} \quad (19)$$

Keterangan:

$P[i]$: Probabilitas relatif dari kromoso ke- i

$f[i]$: Nilai fitness dari kromosom ke- i

$\sum f$: Jumlah total nilai fitness dari seluruh kromosom

Pada masalah minimisasi seperti Mean Absolute Percentage Error (MAPE), nilai fitness perlu dikonversi menjadi fungsi invers agar sesuai dengan prinsip maksimisasi (Sriwindono & Putranto, 2022), dengan rumus:

$$F'[i] = \frac{1}{f[i]} \quad (20)$$

Keterangan:

$F'[i]$: Nilai *fitness* hasil inversi

$f[i]$: Nilai fitness dari kromosom ke- i

Probabilitas relatif tiap individu dihitung menggunakan:

$$P[i] = \frac{F'[i]}{\sum F'} \quad (21)$$

dengan $\sum F'$ adalah Total nilai fitness yang telah dibalik dari seluruh kromosom.

Probabilitas kumulatifnya diperoleh melalui:

$$C[i] = C[i - 1] + P[i] \quad (22)$$

Keterangan:

$C[i]$: Probabilitas kumulatif individu ke- i


$P[i]$: Probabilitas relatif individu ke- i

Pemilihan induk dilakukan dengan membangkitkan bilangan acak $R_i \in (0,1)$; jika $C[i - 1] < R_i \leq C[i]$, maka kromosom ke- i dipilih sebagai induk.

Crossover

Crossover (pindah silang) merupakan operator dalam algoritma genetika yang mengombinasikan dua individu induk untuk membentuk kromosom baru yang mewarisi sifat keduanya, dengan tujuan menghasilkan keturunan yang lebih baik. Proses ini menciptakan titik baru dalam ruang pencarian yang berpotensi meningkatkan kualitas solusi. Pada penelitian ini digunakan metode *One Point Crossover*,

yaitu pertukaran gen yang dilakukan pada satu titik potong tertentu seperti terlihat pada Gambar 1 (Permata et al., 2016).




Gambar 1. One Point Crossover

Pada Gambar 1, proses *crossover* dimulai dengan memilih titik potong pada posisi kedua dari *parent* pertama, sehingga segmen awal hingga titik potong diambil dari *parent* tersebut. Sisa kromosom diambil dari *parent* kedua, dimulai dari posisi setelah titik potong hingga akhir kromosom. Proses ini menghasilkan kromosom baru yang merupakan kombinasi genetik dari kedua *parent*.

Mutasi

Mutasi merupakan mekanisme penting dalam algoritma genetika yang berfungsi mempertahankan keragaman solusi dalam populasi. Proses ini dilakukan dengan mengubah secara acak satu atau beberapa gen pada kromosom untuk menghasilkan variasi baru, sehingga algoritma dapat mengeksplorasi ruang solusi lebih luas dan menghindari konvergensi prematur. Pada penelitian ini digunakan metode *Bit Flip Mutation* seperti terlihat pada Gambar 2.



Gambar 2. Bit Flip Mutation

Proses ini bekerja dengan cara memilih satu atau lebih gen dalam kromosom secara acak, lalu dilakukan pembalikan nilai dengan mengubah bit 0 menjadi 1 atau sebaliknya. Mutasi ini sangat penting untuk menjaga keragaman genetik, terutama ketika proses seleksi dan *crossover* mulai mendominasi populasi dengan individu-individu yang serupa (Simanjuntak et al., 2024)

Ukuran Ketetapan

Ketepatan hasil peramalan dapat diukur menggunakan Mean Absolute Percentage Error (MAPE) dan koefisien korelasi Pearson (r). MAPE menilai rata-rata kesalahan relatif antara nilai aktual dan hasil peramalan, sedangkan korelasi Pearson mengukur kekuatan hubungan linier di antara

keduanya. Rumus MAPE dituliskan sebagai berikut (Tauryawati & Irawan, 2014):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \times 100\% \quad (23)$$

Keterangan:

- Y_t : Data aktual pada periode ke- t
- F_t : Nilai peramalan pada periode ke- t
- n : Banyak data

Tabel 1. Kriteria MAPE

MAPE	Tingkat Akurasi
< 10%	Sangat Baik
10 – 20%	Baik
20 – 50%	Cukup Baik
> 50%	Buruk

Sementara itu, korelasi Pearson dihitung dengan persamaan berikut (Windarto, 2020):

$$r = \frac{\frac{1}{n} \sum_{t=1}^n (Y_t - \bar{Y})(F_t - \bar{F})}{\left[\left(\frac{1}{n} \sum_{t=1}^n (Y_t - \bar{Y})^2 \right) \left(\frac{1}{n} \sum_{t=1}^n (F_t - \bar{F})^2 \right) \right]^{\frac{1}{2}}} \quad \#(24)$$

Keterangan:

- Y_t : Data aktual pada periode ke- t
- \bar{Y} : Rata-rata Data aktual
- F_t : Nilai peramalan pada periode ke- t
- \bar{F} : Rata-rata Hasil Peramalan
- n : Banyak data

Nilai r berkisar antara -1 hingga 1. Nilai mendekati 1 menunjukkan hubungan positif yang sangat kuat, mendekati 0 menunjukkan hubungan yang lemah atau tidak ada, sedangkan mendekati -1 menunjukkan hubungan negatif yang kuat. Dengan demikian, korelasi Pearson memberikan gambaran sejauh mana model peramalan mengikuti pola data aktual secara linier.

Produksi Kopi

Kopi merupakan salah satu komoditas unggulan subsektor perkebunan yang berperan penting dalam peningkatan devisa negara, pendapatan petani, serta penyediaan bahan baku industri dan lapangan kerja melalui kegiatan pengolahan dan perdagangan (Nasirudin et al., 2022). Indonesia menempati posisi kedua produsen kopi terbesar di Asia dan Oseania setelah Vietnam, dengan produksi mencapai 12 juta karung berukuran 60 kg pada periode 2022/2023, sekaligus termasuk dalam lima besar konsumen kopi dunia (International Coffee Organization, 2023).

Meskipun produksi kopi meningkat dari 765.415 ton pada 2021 menjadi 793.193 ton pada 2022, jumlahnya menurun kembali menjadi 760.192 ton pada 2023. Fluktuasi ini disebabkan oleh faktor iklim ekstrem, serangan hama, dan dinamika pasar, yang menimbulkan ketidakpastian dalam perencanaan produksi, pengelolaan stok, serta strategi distribusi.

METODE PENELITIAN

Penelitian ini menggunakan metode *Triple Exponential Smoothing Holt-Winters* yang dioptimasi dengan *Genetic Algorithm* (GA) untuk meramalkan produksi kopi Indonesia. Data sekunder diperoleh dari BPS melalui laman, berupa data bulanan produksi kopi periode Januari 2016–Desember 2023 sebanyak 96 observasi. Analisis dilakukan melalui beberapa tahap, yaitu:


1. [Inisialisasi] Membentuk populasi awal yang terdiri dari n kromosom secara acak.
2. [Evaluasi Fitness] Menghitung nilai *fitness* $f(x)$ untuk setiap kromosom dalam populasi guna menilai kualitas solusinya.
3. [Populasi Baru] Menyusun populasi generasi berikutnya dengan mengulangi langkah-langkah berikut hingga jumlah individu terpenuhi.
4. [Seleksi] Memilih dua kromosom sebagai induk berdasarkan nilai *fitness*-nya – semakin tinggi nilai *fitness*, semakin besar peluang kromosom tersebut untuk dipilih.
5. [Crossover] Melakukan proses *crossover* (perkawinan silang) dengan probabilitas tertentu untuk menghasilkan kromosom keturunan baru. Jika *crossover* tidak terjadi, maka keturunan yang dihasilkan merupakan salinan dari induknya.
6. [Mutasi] Dengan probabilitas mutasi tertentu, dilakukan perubahan (mutasi) pada gen dalam kromosom untuk menjaga keberagaman populasi.
7. [Penerimaan] Menambahkan kromosom keturunan hasil *crossover* dan mutasi ke dalam populasi baru.
8. [Pergantian Populasi] Menggantikan populasi lama dengan populasi baru untuk proses evolusi berikutnya.
9. [Uji Henti] Jika kriteria penghentian telah terpenuhi, proses dihentikan dan solusi terbaik dari populasi dijadikan hasil akhir.

10. [Perulangan] Jika belum memenuhi kriteria penghentian, kembali ke langkah seleksi (d) untuk memulai iterasi berikutnya.

HASIL DAN PEMBAHASAN

Identifikasi Pola Data

Identifikasi pola data dilakukan melalui plot deret waktu produksi kopiperiode Januari 2016–Desember 2023 ditunjukkan pada Gambar 3.



Gambar 3. Deret Waktu Produksi Kopi periode Jan 2016- Des 2023

Gambar 3 menunjukkan tren produksi kopi Indonesia dari Januari 2016 hingga Desember 2023 dengan pola musiman yang konsisten. Produksi mencapai puncak pada Juli–September dan terendah pada Januari–Maret. Pola fluktuasi yang meningkat seiring level produksi menunjukkan karakteristik musiman multiplikatif, sehingga metode *Triple Exponential Smoothing Holt-Winters* tepat digunakan untuk peramalan data ini.

Peramalan Produksi Kopi Menggunakan *Triple Exponential Smoothing Holt-Winters*

Output yang dihasilkan meliputi parameter pemulusan awal, nilai hasil peramalan, serta tingkat akurasi model yang diukur menggunakan *Mean Absolute Percentage Error* (MAPE). Pada tahap awal, parameter pemulusan ditentukan secara *trial and error*. Gardner (2006) menyatakan bahwa parameter pemulusan pada metode *Holt-Winters* yang terlalu besar dapat menyebabkan ketidakstabilan model. Oleh karena itu, ketiga parameter α , β , dan γ umumnya disarankan bernilai kurang dari 0,3 untuk menjaga kestabilan model dan mencegah komponen musiman bernilai negatif. Berdasarkan pertimbangan tersebut, nilai awal $\alpha = 0,1$; $\beta = 0,2$; dan $\gamma = 0,3$ digunakan untuk memberikan gambaran awal terhadap performa model sebelum dilakukan optimasi parameter lebih lanjut. Hasil validasi data *testing Triple Exponential Smoothing Holt-Winters* Aditif dan Multiplikatif ditunjukkan pada Tabel 2.

Tabel 2. Validasi Data *Testing Triple Exponential Smoothing Holt-Winters*

t	Y_t	F_{tAd}	$\frac{ Y_t - F_{tAd} }{Y_t}$	F_{tMult}	$\frac{ Y_t - F_{tMu} }{Y_t}$
Jan 2023	6961	9388	0,3487	3580	0,4858
Feb 2023	6035	9421	0,5610	3077	0,4902
Mar 2023	7435	10433	0,4032	2854	0,6162
Apr 2023	4954	20618	3,1619	12891	1,6021
Mei 2023	6620	32822	3,9580	19546	1,9526
Jun 2023	50327	83346	0,6561	50666	0,0067
Jul 2023	165928	171967	0,0364	102059	0,3849
Agu 2023	190628	185465	0,0271	108419	0,4313
Sep 2023	217618	186238	0,1442	101929	0,5316
Okt 2023	80512	87170	0,0827	50193	0,3766
Nov 2023	12802	28927	1,2596	15608	0,2192
Des 2023	8905	15685	0,7614	5605	0,3705
MAPE (%)			95,0028%		62,2304%

Berdasarkan Tabel 2, pendekatan *Holt-Winters* aditif menghasilkan MAPE sebesar 95,0028%, jauh lebih tinggi dibandingkan pendekatan multiplikatif yang memiliki MAPE sebesar 62,2304%. Meskipun pada beberapa bulan nilai ramalan aditif terlihat lebih besar, hal tersebut tidak menunjukkan akurasi yang lebih baik. Pola ini muncul karena komponen musiman aditif bersifat konstan, sehingga saat level produksi meningkat tajam, ramalan aditif cenderung naik terlalu tinggi. Akibatnya, galat relatif membesar dan MAPE meningkat. Sebaliknya, pendekatan multiplikatif menghasilkan galat yang lebih kecil karena musimannya mengikuti skala data. Ketika level produksi tinggi, ramalan multiplikatif juga naik secara proporsional, sehingga selisih relatif terhadap data aktual lebih kecil. Hal ini menunjukkan bahwa struktur musiman multiplikatif lebih sesuai dengan karakteristik data produksi kopi Indonesia.

A. Pengujian Model *Triple Exponential Smoothing Holt-Winters* dengan *Optimasi Genetic Algorithm*

Setelah diperoleh hasil validasi awal yang menunjukkan bahwa model *Holt-Winters* Multiplikatif memiliki akurasi lebih baik dibandingkan model aditif, tahap selanjutnya adalah menerapkan *Genetic Algorithm* untuk mengoptimasi parameter pemulusan. Pengujian ini, dilakukan dengan menetapkan parameter *Genetic Algorithm* secara tetap, yaitu ukuran populasi 20, *crossover rate* (CR) sebesar 0,9, *mutation rate* (MR) sebesar 0,1, dan jumlah generasi sebanyak 50. Penetapan parameter ini difokuskan untuk menjaga konsistensi kondisi pengujian sehingga perbandingan akurasi antara

model Aditif dan Multiplikatif dapat dilakukan secara setara. Hasil pengujian ditunjukkan pada Tabel 3.

Tabel 3. Pengujian Variasi

α	β	γ	MAPE	
			Ad	Mult
0,0230	0,2851	0,9175	12,2092	0,5024

Berdasarkan Tabel 3, pendekatan multiplikatif menghasilkan MAPE sebesar 0,5024%, lebih baik dibandingkan pendekatan aditif yang memiliki MAPE sebesar 12,2092%. Perbedaan ini mengindikasikan bahwa pola musiman pada data produksi kopi lebih tepat dimodelkan secara multiplikatif karena bersifat proporsional terhadap level data. Selain itu, kinerja *Genetic Algorithm* juga terlihat efektif, di mana proses optimasi mampu menemukan kombinasi parameter α , β , dan γ yang menghasilkan peningkatan akurasi signifikan pada kedua model.

Peramalan Produksi Kopi Menggunakan Triple Exponential Smoothing Holt-Winters dengan Optimasi Parameter Genetic Algorithm

Berdasarkan hasil percobaan, diperoleh nilai optimal parameter α, β , dan γ melalui proses optimasi menggunakan Algoritma Genetika, masing-masing sebesar α sebesar 0,0230, β sebesar 0,2851, dan γ sebesar 0,9175. Parameter optimal ini kemudian disubstitusikan ke dalam persamaan smoothing level, tren, dan musiman untuk membentuk model Holt-Winters yang telah dioptimasi. Hasil validasi pada data testing untuk metode Triple Exponential Smoothing Holt-Winters Aditif dan Multiplikatif disajikan pada Tabel 5.

Tabel 4. Validasi Data Testing Triple Exponential Smoothing Holt-Winters dengan Optimasi Parameter Genetic Algorithm.

t	Y_t	$F_{t Ad}$	$\left \frac{Y_t - F_{t Ad}}{Y_t} \right $	$F_{t Mult}$	$\left \frac{Y_t - F_{t Mu}}{Y_t} \right $
Jan 2023	6961	8422	0,3487	6970	0,4858
Feb 2023	6035	7373	0,5610	6024	0,4902
Mar 2023	7435	8746	0,4032	7439	0,6162
Apr 2023	4954	6145	3,1619	4964	1,6021
Mei 2023	6620	7753	3,9580	6607	1,9526
Jun 2023	50327	52568	0,6561	50523	0,0067
Jul 2023	165928	170823	0,0364	166251	0,3849
Agu 2023	190628	196253	0,0271	190994	0,4313
Sep 2023	217618	232552	0,1442	226280	0,5316
Okt 2023	80512	83307	0,0827	80401	0,3766
Nov 2023	12802	14116	1,2596	12830	0,2192
Des 2023	8905	10118	0,7614	8892	0,3705

t	Y_t	$F_{t Ad}$	$\left \frac{Y_t - F_{t Ad}}{Y_t} \right $	$F_{t Mult}$	$\left \frac{Y_t - F_{t Mu}}{Y_t} \right $
MAPE (%)			12,2092		0,5024%
			%		

Berdasarkan Tabel 4, optimasi menggunakan *Genetic Algorithm* berhasil meningkatkan akurasi secara signifikan pada kedua pendekatan. Pendekatan multiplikatif mencapai MAPE 0,5024%, jauh lebih rendah dibandingkan pendekatan aditif yang memiliki MAPE 12,2092%. Pada beberapa periode, ramalan aditif memang tampak lebih besar, tetapi hal ini disebabkan oleh musiman konstan yang menyebabkan ramalan mudah menjadi berlebihan ketika level data naik. Kondisi ini tetap menghasilkan galat relatif tinggi sehingga MAPE tidak dapat turun secara optimal. Sebaliknya, pendekatan multiplikatif memberikan nilai ramalan yang proporsional terhadap level produksi, sehingga kesalahan relatifnya kecil dan stabil di seluruh periode. Hal ini membuat pendekatan multiplikatif jauh lebih akurat setelah optimasi GA, sekaligus menegaskan bahwa pola musiman data produksi kopi bersifat multiplikatif.

B. Hasil Peramalan Produksi Kopi Menggunakan Metode Triple Exponential Smoothing Holt-Winters dengan Optimasi Parameter Genetic Algorithm

Setelah penerapan metode Triple Exponential Smoothing (TES) Holt-Winters dalam peramalan produksi kopi Indonesia, baik sebelum maupun sesudah optimasi parameter menggunakan Genetic Algorithm (GA), dilakukan tahap validasi menggunakan data testing tahun 2023. Validasi ini bertujuan untuk menilai ketepatan hasil peramalan berdasarkan ukuran galat Mean Absolute Percentage Error (MAPE). Ringkasan nilai MAPE dari setiap pendekatan peramalan ditampilkan pada Tabel 6.

Tabel 6. Ringkasan Akurasi Peramalan Metode Holt-Winters dan Optimasi Genetic Algorithm

Model	MAPE(%)	Korelasi
TES Holt-Winters Aditif	95,0028	0,9740
TES Holt-Winters Multiplikatif	62,2304	0,9850
TES Holt-Winters Aditif + GA	12,2092	0,9997
TES Holt-Winters Multiplikatif + GA	0,5024	0,9997

Tabel 6 menunjukkan bahwa penerapan TES Holt-Winters tanpa optimasi menghasilkan tingkat kesalahan yang masih tinggi, baik pada pendekatan aditif (MAPE 95,0028%) maupun multiplikatif (MAPE 62,2304%). Meskipun keduanya dapat

mengikuti bentuk pola umum deret waktu (dibuktikan oleh korelasi $> 0,97$), skala prediksinya belum akurat sehingga galat relatif tetap besar. Setelah dilakukan optimasi menggunakan *Genetic Algorithm*, akurasi meningkat secara signifikan. Pada pendekatan aditif, MAPE menurun hingga 12,2092%, sedangkan pada pendekatan multiplikatif penurunan jauh lebih drastis hingga mencapai 0,5024%. Korelasi pada kedua pendekatan yang telah dioptimasi meningkat menjadi 0,9997, menunjukkan kesesuaian pola prediksi dengan data aktual yang sangat tinggi.

PENUTUP

Penerapan metode *Triple Exponential Smoothing Holt-Winters* yang dioptimasi menggunakan *Genetic Algorithm* (GA) terbukti mampu meningkatkan akurasi peramalan produksi kopi Indonesia secara signifikan. Berdasarkan hasil analisis, produksi kopi Indonesia menunjukkan pola musiman yang bersifat proporsional terhadap level data, sehingga pendekatan multiplikatif pada metode *Triple Exponential Smoothing Holt-Winters* lebih sesuai dibandingkan pendekatan aditif. Peramalan tanpa optimasi masih menghasilkan galat yang tinggi, ditunjukkan oleh MAPE sebesar 95,0028% pada aditif dan 62,2304% pada multiplikatif. Setelah parameter pemulusan dioptimasi menggunakan *Genetic Algorithm*, akurasi meningkat drastis dengan MAPE turun menjadi 12,2092% pada aditif dan 0,5024% pada multiplikatif, disertai korelasi mendekati 1 yang menunjukkan kesesuaian hasil ramalan dengan data aktual. Dengan demikian, pendekatan *Holt-Winters* multiplikatif yang dioptimasi *Genetic Algorithm* merupakan pendekatan paling akurat dan paling mampu menggambarkan pola musiman produksi kopi Indonesia.

DAFTAR PUSTAKA

- Andriani, N., Wahyuningsih, S., & Siringoringo, M. (2022). Application of Double *Exponential Smoothing Holt* and *Triple Exponential Smoothing Holt-Winter* with Golden Section Optimization to Forecast Export Value of East Borneo Province. *Jurnal Matematika, Statistika Dan Komputasi*, 18(3), 475–483. <https://doi.org/10.20956/j.v18i3.17492>
- Aryati, A., Purnamasari, I., & Nasution, Y. N. (2020). Peramalan dengan Menggunakan Metode *Holt-Winters Exponential Smoothing* (Studi Kasus: Jumlah Wisatawan Mancanegara yang Berkunjung Ke Indonesia). *Jurnal EKSPONENSIAL*, 11(1), 99–105.
- Djazuli, R. A., Hariyono, A., Anggun, A. R., Nuha, S. U., & Ibrahim, A. L. (2024). *Perancangan Usaha Agribisnis*.
- Hakemi, S., Houshmand, M., & Hosseini, S. A. (2023). A Modified Quantum-Inspired *Genetic Algorithm* Using Lengthening Chromosome Size and an Adaptive Look-Up Table to Avoid Local Optima. *Axioms*, 12(978), 1–21.
- Hariato, L., Imran, M., & Gamal, M. D. H. (2025). Penerapan Algoritma Genetika pada Persoalan Pemotongan Stok Satu Dimensi. *Journal of Science and Technology in the Tropics*, 5(1), 69–80.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice (2nd ed.)*. [https://books.google.co.id/books?id=_bBhDwAAQBAJ&lpg=PA7&ots=Tjj_sfYOMP&dq=Hyndman%2C R. J.%2C %26 Athanasopoulos%2C G. \(2018\). Forecasting%3A Principles and Practice \(2nd ed.\). OTexts. OTexts.com%2Ffpp2.&lr&hl=id&pg=PA7#v=onepage&q&f=false](https://books.google.co.id/books?id=_bBhDwAAQBAJ&lpg=PA7&ots=Tjj_sfYOMP&dq=Hyndman%2C R. J.%2C %26 Athanasopoulos%2C G. (2018). Forecasting%3A Principles and Practice (2nd ed.). OTexts. OTexts.com%2Ffpp2.&lr&hl=id&pg=PA7#v=onepage&q&f=false)
- Ilahi, R., & Agustin, B. (2022). Peramalan Nilai Tukar Petani Di Bangka Belitung Dengan Metode *Holt-Winters*. *Jurnal Fraction*, 2(2), 66–73. <https://doi.org/10.33019/fraction.v2i2.34>
- Indonesia., K. P. R. (2023). *Outlook Komoditas Perkebunan: Kopi 2023*.
- International Coffee Organization. (2023). Coffee Report and Outlook. *International Coffee Organization ICO*, 1(1), 1–39. https://icocoffee.org/documents/cy2023-24/Coffee_Report_and_Outlook_December_2023_ICO.pdf
- Mitchell, M. (1998). An Introduction To *Genetic Algorithms*. In *MIT Press*. <https://doi.org/10.1007/BF02823145>
- Mujahid, W., Tiro, M. A., & Rusliana. (2022). Pemodelan Laju Inflasi Dengan Menggunakan Regresi Non-Linear Berbasis Algoritma Genetika (Kasus: Kota-Kota di Pulau Jawa). *VARIANSI: Journal of Statistics and Its*

- Application on Teaching and Research*, 4(1), 20–29.
<https://doi.org/10.35580/variasiunm7>
- Nasirudin, F., Pindianti, M., Said, D. I. S., & Widodo, E. (2022). Peramalan Jumlah Produksi Kopi Di Jawa Timur Pada Tahun 2020-2021 Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *Agrium*, 25(1), 34–43.
<https://doi.org/https://doi.org/10.30596/agrium.v25i1.8211>
- Nufus, S. A., & Sutarman. (2022). Penaksiran Parameter Distribusi Weibull Menggunakan Algoritma Genetika dan Particle Swarm Optimization. *FARABI: Jurnal Matematika Dan Pendidikan Matematika*, 5(2), 128–137.
<https://doi.org/10.47662/farabi.v5i2.401>
- Permata, R. A., Triyanto, D., & Ilhamsyah. (2016). Aplikasi Penyusun Menu Makanan Untuk Pencegahan Hiperkolesteromia Menggunakan Algoritma Genetika. *Jurnal Coding Sistem Komputer Untan*, 04(2), 96–106.
- Puspita, R. N. (2022). Perbandingan Metode Double Exponential Smoothing Dan Triple Exponential Smoothing Pada Peramalan Nilai Ekspor Di Indonesia. *Jambura Journal of Probability and Statistics*, 3(2), 141–150.
<https://doi.org/10.34312/jjps.v3i2.15590>
- Ramadhilah, B., & Masjud, Y. I. (2024). *Climate change impacts on coffee production in Indonesia: A review*. 1(1), 1–7.
- Rizal, M., Indah, D. R., & Meutia, R. (2021). Analisis Peramalan Produksi Menggunakan Trend Moment Pada Kilang Padi Do'a Ibu Diperlak Kecamatan Pereulak. *Jurnal Samudra Ekonomika*, 5(1), 161–168.
<https://doi.org/10.33059/jse.v5i2.4274>
- Simanjuntak, P., Aritonang, M. A. S., Wantouw, F., Siahaan, R. D., Ardiansyah, M., Purba, S. E. M., Lazine, V., Hutapea, O., Pardede, C., Salim, M., Ahmad, S. R. N., & Hutagalung, C. A. (2024). Kecerdasan buatan. In *Yayasan Tri Edukasi Ilmiah*.
- Sriwindono, H., & Putranto, R. E. (2022). Optimisasi Parameter Metode Holt-Winter Dengan Menggunakan Algoritma Genetika. *SNISTEK*, 4, 256–261.
<https://forum.upbatam.ac.id/index.php/prosiding/article/view/5269%0Ahttps://forum.u>
[pbatam.ac.id/index.php/prosiding/article/download/5269/2421](https://forum.upbatam.ac.id/index.php/prosiding/article/download/5269/2421)
- Tauryawati, M. L., & Irawan, M. I. (2014). Perbandingan Metode Fuzzy Time Series Cheng dan Metode Box-Jenkins untuk Memprediksi IHSG. *Jurnal Sains Dan Seni Pomits*, 3(2), 34–39. www.idx.co.id
- Violina, D., Nuraini, D., Anamisa, D. R., Khotimah, B. K., Jauhari, A., & Ayu, F. M. (2025). Prediksi Panen Padi Di Madura Dengan Triple Exponential Smoothing (TES) dan Algoritma Genetika. *JUSIFOR: Jurnal Sistem Informasi Dan Informatika*, 4(1), 9–16.
- Whardhana, A. F., Pratiwi, A. B., & Winarko, E. (2024). *Penyelesaian Unit Commitment Problem (UCP) Menggunakan Algoritma Genetika*. 5(2), 93–104.