

BAB I PENDAHULUAN

1.1 Latar Belakang

Indonesia adalah negara yang memiliki basis agraris, perekonomiannya sangat bergantung pada sektor pertanian. Pada tahun 2023, sektor Pertanian, Kehutanan, dan Perikanan memberikan kontribusi signifikan sekitar 12,53% terhadap Produk Domestik Bruto (PDB) Indonesia. Hal ini menjadikannya sebagai sektor penyumbang ketiga terbesar setelah sektor Industri Pengolahan dan Perdagangan. Salah satu subsektor yang menjadi perhatian utama adalah subsektor perkebunan, yang menunjukkan potensi besar setiap tahunnya. Pada tahun 2023, kontribusinya mencapai 3,88% terhadap total PDB nasional dan 30,99% terhadap PDB sektor Pertanian, Kehutanan, dan Perikanan (Badan Pusat Statistika, 2024). Kopi merupakan salah satu komoditas unggulan dalam subsektor perkebunan. Kopi tidak hanya berperan sebagai sumber devisa negara, tetapi juga sebagai sumber pendapatan bagi para petani, penghasil bahan baku industri, maupun penyedia lapangan kerja melalui aktivitas pengolahan, pemasaran, dan perdagangan (ekspor dan impor) (Nasirudin et al., 2022).

Indonesia bahkan menempati posisi kedua sebagai produsen kopi terbesar di Asia dan Oseania setelah Vietnam, dengan total produksi mencapai 12 juta karung berukuran 60 kg pada tahun 2022/2023 (International Coffee Organization, 2023). Selain sebagai negara penghasil, Indonesia juga termasuk lima besar konsumen kopi dunia. Meskipun produksi meningkat dari 765.415 ton pada 2021 menjadi 793.193 ton pada 2022, produksi kopi mengalami fluktuasi dengan penurunan menjadi 760.192 ton pada tahun 2023. Fluktuasi disebabkan berbagai faktor seperti perubahan iklim ekstrem, serangan hama, maupun dinamika pasar. Kondisi tersebut menimbulkan ketidakpastian dalam perencanaan pemenuhan kebutuhan pasar, manajemen stok, dan strategi distribusi yang pada akhirnya berpotensi memengaruhi stabilitas ekonomi di daerah sentra produksi. Untuk meminimalkan ketidakpastian tersebut, diperlukan suatu pendekatan matematis melalui metode peramalan (Djazuli et al., 2024).

Peramalan adalah kegiatan memprediksi kejadian di masa depan dengan menganalisis data atau informasi dari periode sebelumnya (Rizal et al., 2021). Proses ini dilakukan secara sistematis melalui berbagai pendekatan, baik kualitatif maupun kuantitatif, guna memperoleh gambaran kondisi mendatang yang lebih akurat (Alfinatuzzahro et al., 2024). Data yang digunakan dalam peramalan umumnya berupa deret waktu, yaitu informasi historis dalam kurun waktu tertentu



1. Analisis deret waktu mampu mengidentifikasi pola musiman, serta fluktuasi data masa lalu yang dijadikan dasar untuk depan. Dengan penerapan metode yang tepat, peramalan akan secara lebih akurat sehingga mendukung perencanaan manajemen stok, dan strategi pemasaran. Oleh karena itu, metode deret waktu sangat penting dalam meningkatkan efisiensi rantai pasok dan

pengambilan keputusan pada sektor perkebunan (Rangapuram et al., 2018). Namun demikian, ketidakpastian dalam peramalan tidak dapat sepenuhnya dihindari, sehingga akurasi maupun potensi penyimpangan harus diperhitungkan secara cermat (Anggraeni & Arifin, 2022). Tujuan utama peramalan adalah menghasilkan prediksi yang meminimalkan tingkat kesalahan yang mungkin terjadi (Fauziah et al., 2019).

Terdapat beberapa metode yang dapat digunakan dalam melakukan peramalan. Beberapa di antaranya adalah metode *Moving Average* (MA), *Autoregressive Integrated Moving Average* (ARIMA), dan *Exponential Smoothing* (Aryati et al., 2020). Salah satu metode yang banyak digunakan adalah *Exponential Smoothing*, yaitu teknik pemulusan deret waktu yang secara terus-menerus memperbarui hasil prediksi dengan menghitung rata-rata *Smoothing* dari data historis dan memberikan bobot menurun secara eksponensial terhadap observasi yang lebih lama. Metode ini memiliki tiga varian utama, yaitu *Single Exponential Smoothing*, *Double Exponential Smoothing*, dan *Triple Exponential Smoothing* (Ilahi & Agustin, 2022). Namun, masalah utama dalam penggunaan metode *Exponential Smoothing* terletak pada keterbatasannya dalam menangani data dengan pola yang lebih kompleks karena *Single Exponential Smoothing* hanya memodelkan komponen level, sedangkan *Double Exponential Smoothing* (Holt) hanya mencakup level dan tren, sehingga kurang optimal jika diterapkan pada data yang memiliki unsur musiman eksplisit. Untuk mengatasi keterbatasan tersebut, digunakan metode *Triple Exponential Smoothing Holt-Winters* yang mampu mengakomodasi ketiga komponen utama data deret waktu sekaligus, yaitu *level*, *tren*, dan *musiman* (Puspita, 2022).

Penelitian oleh Amri et al. (2025) menunjukkan bahwa metode *Triple Exponential Smoothing Holt-Winters* mampu menangkap pola tren dan musiman secara dinamis serta efektif dalam memprediksi arah perubahan harga beras di pasar grosir Indonesia sepanjang tahun. Sementara itu, penelitian oleh Yusuf & Anjasari (2018) membuktikan bahwa meskipun parameter pemulusan yang digunakan pada model aditif dan multiplikatif sama, hasil peramalan menunjukkan nilai MAPE dan MSE yang lebih rendah pada model yang sesuai dengan karakteristik data musiman. Hal ini menegaskan bahwa pemilihan model yang tepat sangat penting dalam meningkatkan akurasi peramalan, sebagaimana dibuktikan dalam studi peramalan jumlah wisatawan nusantara di Kabupaten Banyuwangi pada periode April 2018 hingga Maret 2019. Kedua penelitian ini memperkuat bahwa metode *Triple Exponential Smoothing Holt-Winters* layak diterapkan pada data deret waktu yang memiliki pola tren dan musiman.



Metode *Triple Exponential Smoothing Holt-Winters* memiliki kemampuan untuk menangani data dengan tren dan musiman, permasalahan utama dalam peramalan adalah proses pemilihan parameter yang biasanya dilakukan secara manual. Proses ini memerlukan waktu cukup lama dan hasil yang belum tentu akurat. Oleh karena itu, digunakan pendekatan yang lebih efisien, yaitu salah satu metode *Genetic Algorithm*. Algoritma ini merupakan metode komputasi

untuk masalah optimasi yang terinspirasi oleh teori evolusi. Algoritma ini bekerja berdasarkan prinsip evolusi biologis dengan melibatkan proses seleksi, *crossover*, dan mutasi, untuk menjelajahi ruang solusi secara lebih luas serta menghindari jebakan optimum lokal (Sriwindono & Putranto, 2022). Terdapat berbagai variasi pada *Genetic Algorithm*, salah satunya adalah *Genetic* optimasi kombinasi, untuk mendapatkan solusi yang optimal terhadap suatu masalah yang memiliki banyak kemungkinan solusi (Syahputra & Yahfizham, 2024).

Penelitian yang dilakukan oleh Violina et al. (2025) menunjukkan bahwa penggunaan teknik optimasi dalam model peramalan dapat meningkatkan akurasi hasil prediksi. *Triple Exponential Smoothing* yang dikombinasikan dengan *Genetic Algorithm* terbukti mampu menurunkan tingkat kesalahan peramalan secara signifikan dalam kasus peramalan hasil panen padi di Madura. Sementara itu, penelitian Nufus & Sutarman (2022) membandingkan performa *Genetic Algorithm* dengan *Particle Swarm Optimization* (PSO) dalam penaksiran parameter distribusi *Weibull* dua dan tiga parameter. Hasil penelitian tersebut membuktikan bahwa *Genetic Algorithm* lebih unggul karena dilengkapi operator evolusi seperti *crossover* dan mutasi, yang memungkinkannya melakukan optimasi pada permasalahan kompleks dengan ruang pencarian yang luas. Kedua penelitian ini menegaskan bahwa *Genetic Algorithm* efektif digunakan sebagai metode optimasi pada berbagai permasalahan prediksi maupun estimasi parameter.

Penelitian ini menggunakan optimasi parameter *Genetic Algorithm*. Data yang diperoleh dari Badan Pusat Statistik Indonesia mengenai produksi kopi Indonesia tahun 2016 sampai dengan 2023 menunjukkan pola grafik dengan tren dan faktor musiman, sehingga metode *Triple Exponential Smoothing Holt-Winters* dianggap tepat untuk digunakan dalam penelitian ini. Oleh karena itu, peneliti mengangkat judul tentang "**Penerapan *Genetic Algorithm* Dalam Optimasi Metode *Triple Exponential Smoothing Holt-Winters* (Studi Kasus: Produksi Kopi Indonesia Tahun 2023)**". Hasil dari penelitian ini diharapkan dapat membantu pemerintah sebagai acuan dalam perhitungan peramalan produksi, khususnya dalam pengambilan kebijakan yang berhubungan terkait produksi kopi periode ke depan.

1.2 Batasan Masalah

Batasan masalah dalam penelitian ini bertujuan untuk merinci dan membatasi cakupan serta lingkup topik penelitian agar lebih fokus adalah:

1. Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik yaitu data produksi kopi Indonesia pada periode sampai dengan Desember 2023.



parameter α , β , dan γ pada *Triple Exponential Smoothing Holt-Winters* optimasi *Genetic Algorithm* dengan nilai presisi parameter

1.3 Tujuan dan Manfaat Penelitian

Tujuan penelitian ini adalah:

1. Memperoleh estimasi parameter pemulusan pada metode *Triple Exponential Smoothing Holt-Winters* berdasarkan metode optimasi *Genetic Algorithm* pada peramalan data produksi kopi Indonesia.
2. Memperoleh hasil peramalan produksi kopi Indonesia tahun 2023 dengan tingkat akurasi terbaik menggunakan metode *Triple Exponential Smoothing Holt-Winters* dengan optimasi *Genetic Algorithm*.


Manfaat yang diharapkan dari penelitian ini meliputi.

1. Memberikan kontribusi pada ilmu statistika dan *data science* melalui pengembangan literatur integrasi *Genetic Algorithm* dengan Metode *Triple Exponential Smoothing Holt-Winters* untuk peramalan deret waktu komoditas pertanian.
2. Memberikan hasil peramalan produksi kopi yang akurat dapat menjadi rujukan strategis bagi pemerintah dan industri dalam perencanaan serta pengambilan keputusan guna menjaga stabilitas dan mengoptimalkan produksi kopi nasional.

1.4 Teori

1.4.1 Analisis Deret Waktu

Analisis deret waktu adalah metode statistik yang digunakan untuk menganalisis data yang dikumpulkan secara berurutan berdasarkan interval waktu, seperti harian, bulanan, atau tahunan (Prasetya et al., 2020). Tujuan utama dari analisis ini adalah untuk memahami struktur data, mengidentifikasi pola, dan melakukan peramalan nilai di masa depan berdasarkan data historis. Metode ini banyak diterapkan dalam berbagai bidang, seperti ekonomi, keuangan, meteorologi, dan produksi, untuk mengidentifikasi tren, pola musiman, dan fluktuasi lainnya dalam data (Admirani, 2018). Peramalan data dalam analisis runtun waktu sangat dipengaruhi oleh keseluruhan data observasi karena setiap observasi saling berkorelasi (Mardania et al., 2024). Pemilihan metode deret waktu yang tepat didasarkan pada tipe pola data yang akan di prediksi seperti pada Gambar 1 yaitu: (Lusiana & Yuliarty, 2020).



Gambar 1. Pola Data Deret Waktu (a) Pola Data Horizontal (b) Pola Data Musiman (c) Pola Data Siklis (d) Pola Data Tren

Analisis deret waktu, pola data horizontal (atau stasioner) terjadi ketika nilai-nilai data cenderung stabil di sekitar rata-rata yang konstan sepanjang waktu. Deret data yang menunjukkan stabilitas tanpa adanya tren naik, turun, musiman, atau fluktuasi lainnya.

- b. Pola data musiman, pola data ini dicirikan oleh fluktuasi yang berulang dalam interval waktu yang tetap dan spesifik, seperti bulanan, kuartalan, atau harian. Pada grafik, pola ini seringkali terlihat sebagai puncak (*peaks*) dan lembah (*valleys*) yang konsisten dan periodik, mencerminkan pengaruh faktor-faktor musiman tertentu.
- c. Pola data siklis, pola data ini mengacu pada fluktuasi data yang berlangsung dalam jangka panjang, seringkali dipengaruhi oleh kondisi ekonomi atau siklus bisnis. Pergerakan dalam pola siklis ini menyerupai gelombang dengan durasi lebih dari satu tahun dan tidak selalu memiliki interval pengulangan yang konsisten atau teratur.
- d. Pola data tren, pola data menunjukkan adanya peningkatan atau penurunan jangka panjang yang konsisten dalam serangkaian data. Tren dapat bersifat *linear* (naik atau turun secara konstan) atau *non-linear* (perubahan dengan laju yang bervariasi).

1.4.2 Exponential Smoothing

Exponential Smoothing merupakan salah satu metode analisis deret waktu yang menggunakan pembobotan eksponensial pada masa lalu. Metode ini merupakan perkembangan dari metode *moving average* sederhana. Metode *Exponential Smoothing* memiliki tiga tingkatan yaitu *Single Exponential Smoothing*, *Double Exponential* dan *Triple Exponential Smoothing* (Aryati et al., 2020)..

Single Exponential Smoothing 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) dengan rumus peramalan seperti persamaan 1 sebagai berikut:

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

Dengan,

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

Double Exponential Smoothing Holt digunakan untuk peramalan data runtun waktu yang mengandung unsur tren dan memerlukan dua parameter *Smoothing* yaitu alpha (α) dan beta (β). Inisialisasi nilai awal dilakukan untuk tren sebagai berikut (Andriani et al., 2022):

$$L_1 = Y_1 \quad (2)$$

$$T_1 = Y_2 - Y_1 \quad (3)$$

Level, tren, dan peramalan pada periode ke- t ditunjukkan pada berikut.

$$S_t = \alpha Y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (4)$$



$$b_t = \beta (S_t + S_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

$$F_{t+m} = S_t + b_t m \quad (6)$$

Dengan,

Y_t	: Nilai aktual data pada periode ke- t
S_t	: Nilai pemulusan <i>level</i> (nilai dasar data pada periode ke- t)
b_t	: Nilai pemulusan <i>trend</i> (nilai dasar data pada periode ke- t)
α	: Konstanta pemulusan ($0 \leq \alpha \leq 1$)
β	: Parameter pemulusan ($0 \leq \alpha \leq 1$)
F_t	: Nilai peramalan pada periode ke- t
m	: Periode waktu yang akan diramalkan

Diketahui bahwa *Single Exponential Smoothing* digunakan untuk data runtun waktu yang bersifat stasioner tanpa tren dan musiman, sedangkan *Double Exponential Smoothing Holt* digunakan untuk data yang mengandung unsur tren. Namun, dalam banyak kasus, data runtun waktu tidak hanya memiliki tren, tetapi juga mengandung pola musiman. Oleh karena itu, diperlukan metode pengembangan yang mampu mengakomodasi unsur level, tren, dan musiman secara simultan, yaitu *Triple Exponential Smoothing Holt-Winters*.

1.4.3 Triple Exponential Smoothing Holt-Winters

Triple Exponential Smoothing Holt-Winters adalah salah satu varian dari *Exponential Smoothing*. Dalam metode ini, digunakan persamaan peramalan dan tiga persamaan pemulusan yang meliputi *level*, *trend*, dan komponen musiman, dengan parameter pemulusan yang terdiri dari α , β , dan γ . Metode *Triple Exponential Smoothing Holt-Winters* mempunyai dua jenis musiman, yaitu aditif dan multiplikatif. Pendekatan aditif digunakan apabila data menunjukkan adanya fluktuasi tren dan pola musiman yang relatif konstan seiring bertambahnya waktu. Sebaliknya, pendekatan multiplikatif digunakan apabila data menunjukkan adanya tren dan pola musiman yang berubah-ubah seiring bertambahnya waktu (Andriani et al., 2022).

Menginisialisasi metode *Triple Exponential Smoothing Holt-Winter*, diperlukan penentuan nilai awal untuk parameter *Smoothing level*, *Smoothing* faktor tren, dan *Smoothing* faktor musiman. Estimasi nilai awal konstanta *Smoothing level* didapatkan dengan menggunakan nilai rata-rata pada musim pertama, seperti ditunjukkan pada Persamaan 7 (Hyndman & Athanasopoulos, 2018).



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

trend diperoleh melalui Persamaan 8 sebagai berikut.

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

musiman pada model aditif dihitung menggunakan Persamaan

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

Pada model multiplikatif seperti Persamaan 10.

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

Dengan,

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

Persamaan yang digunakan dalam implementasi pemulusan TES *Holt-Winters* pada model aditif ditunjukkan pada Persamaan sebagai berikut.

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

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

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

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

Persamaan yang digunakan dalam implementasi pemulusan TES *Holt-Winters* pada model multiplikatif ditunjukkan pada Persamaan sebagai berikut.

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

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

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

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

Dengan,

Y_t	: Data aktual pada periode ke- t
α	: Konstanta pemulusan untuk S_t
S_t	: Nilai pemulusan <i>level</i> pada periode t
β	: Konstanta pemulusan untuk b_t
b_t	: Nilai pemulusan tren pada periode t
l_{t-s}	: Nilai pemulusan musiman $t - s$ pada periode t
γ	: Konstanta pemulusan untuk S_t
l_t	: Nilai pemulusan musiman pada periode t
m	: Panjang waktu peramalan
F_{t+m}	: Hasil peramalan pada periode $t + m$




Algorithm

Algorithm pertama kali dikembangkan oleh John Holland pada tahun 1960 di Michigan New York, Amerika Serikat. Dalam bukunya yang berjudul *Adaptation in Natural and Artificial Systems* (1975), Holland memperkenalkan algoritma genetika sebagai abstraksi dari evolusi biologis. Seleksi alam dan variasi genetik. *Genetic Algorithm* merupakan

salah satu teknik pencarian dan optimasi yang dirancang untuk menemukan solusi terbaik dari suatu permasalahan yang memiliki ruang solusi yang luas dan kompleks. Metode ini bekerja dengan mengevaluasi sejumlah solusi kandidat, kemudian secara iteratif memilih solusi-solusi tersebut hingga diperoleh solusi yang paling optimal berdasarkan fungsi evaluasi tertentu yang disebut sebagai fungsi *fitness*. Algoritma ini termasuk dalam kelompok algoritma evolusioner dengan menggunakan evolusi Darwin di bidang Biologi seperti pewarisan sifat, seleksi alam, mutasi genetik, dan rekombinasi (*crossover*). *Genetic Algorithm* juga diklasifikasikan sebagai bagian dari algoritma metaheuristik karena kemampuannya dalam menyelesaikan permasalahan optimasi yang tidak dapat diselesaikan secara konvensional atau analitik, khususnya dalam bidang ilmu komputer dan Teknik (Mitchell, 1998).

Konsep dan terminologi dalam algoritma genetika dapat dilihat sebagai berikut (Rifky et al., 2024):



Gambar 2. Ilustrasi Hubungan Terminologi *Genetic Algorithm*

Ilustrasi pada gambar tersebut memperlihatkan bagaimana setiap elemen genetik saling berkaitan dalam menyusun suatu solusi pada GA. Rincian masing-masing elemen dijelaskan sebagai berikut:

1. **Genotype (Gen)**, sebuah nilai yang menyatakan satuan dasar yang membentuk suatu arti tertentu dalam satu kesatuan gen yang dinamakan kromosom. Dalam Algoritma Genetika, gen ini bisa berupa nilai *biner*, *float*, *integer* maupun karakter, atau kombinatorial



suatu gen.
upakan gabungan dari sekumpulan gen yang membentuk satu
emiliki nilai tertentu.
takan satu nilai atau keadaan yang akan diproses bersama
s proses.
akan sekumpulan dari individu yang akan diproses bersama
s evolusi.

6. Generasi, menyatakan satu siklus proses evolusi atau satu iterasi di dalam algoritma genetika.

Gambar 2 menampilkan struktur dan hubungan terminologi dalam *Genetic Algorithm* yang disusun secara hierarkis. Pada tingkat paling dasar terdapat *allele*, yaitu unit terkecil yang menyusun sebuah gen. Sekumpulan *allele* kemudian membentuk gen, dan beberapa gen selanjutnya tersusun menjadi kromosom. Kromosom berfungsi sebagai representasi suatu solusi atau individu dalam *Genetic Algorithm*. Sekumpulan individu yang dihimpun dalam satu generasi disebut populasi. Populasi inilah yang menjadi objek utama dalam proses evolusi, di mana setiap generasi akan mengalami tahapan seleksi, *crossover*, dan mutasi untuk menghasilkan populasi baru yang lebih adaptif. Dengan demikian, gambar ini secara runtut memperlihatkan keterkaitan antara *allele*, gen, kromosom, individu, dan populasi serta alur pembentukan hingga proses evolusi dalam *Genetic Algorithm* (Simanjuntak et al., 2024).

1.4.4.1 Dekode Kromosom

Dekode kromosom adalah tahapan mengubah isi dalam kromosom menjadi nilai-nilai tertentu yang mewakili masing-masing variabel yang terdiri dari sejumlah bit. Proses ini bertujuan merepresentasikan sifat genotipe dan fenotipe pada suatu populasi. Genotipe digambarkan sebagai deretan bilangan biner dalam kromosom dan digunakan dalam mekanisme genetika seperti *crossover*, mutasi, serta proses evolusioner lainnya. Sementara itu, fenotipe merupakan hasil interpretasi dari dekode kromosom dan digunakan untuk menilai kualitas atau nilai kromosom (Hakemi et al., 2023).

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.

1.4.4.2 Pembentukan Populasi Awal

Pembentukan populasi awal adalah proses membangkitkan sejumlah individu yang acak atau mengikuti prosedur tertentu. Ukuran untuk populasi adalah yang akan diselesaikan dan jenis operator genetika yang akan digunakan. Setelah ukuran populasi ditentukan, kemudian dilakukan inisialisasi awal. Pembangkitan populasi awal dapat dilakukan dengan menggunakan *random generator*, pendekatan tertentu dan permutasi gen. Sebagai titik awal bagi algoritma, menyediakan berbagai solusi untuk proses optimasi yang sedang dikerjakan (Simanjuntak et al., 2024).



1.4.4.3 Evaluasi Fitness

Setiap generasi, kromosom akan dievaluasi menggunakan ukuran yang disebut *fitness*. Nilai *fitness* dari sebuah kromosom menggambarkan kualitas kromosom dalam populasi berdasarkan fungsi tujuan yang telah ditetapkan. Proses ini melibatkan evaluasi setiap individu dalam populasi dengan menghitung nilai *fitness* dan terus berlanjut hingga kriteria berhenti tercapai (Harianto et al., 2025). Penilaian ini dilakukan dengan menghitung nilai *fitness* dari masing-masing individu, yang mencerminkan seberapa baik solusi tersebut dalam menyelesaikan permasalahan. Apabila tujuan optimasi adalah untuk memaksimalkan nilai fungsi, maka nilai *fitness* dapat langsung diambil dari hasil perhitungan fungsi tersebut. Namun, jika tujuan optimasi adalah meminimalkan nilai fungsi, maka nilai *fitness* dihitung sebagai invers atau transformasi lain dari nilai fungsi tersebut agar tetap sesuai dengan prinsip seleksi berbasis nilai maksimum (Simanjuntak et al., 2024).

1.4.4.4 Seleksi

Seleksi dilakukan untuk memilih individu terbaik sebagai keturunan bagi generasi berikutnya. Proses seleksi bertujuan memilih individu terbaik dalam populasi yang diharapkan dapat menghasilkan keturunan dengan nilai *fitness* yang lebih besar (Mayyani et al., 2023). Individu-individu yang terpilih akan dijadikan orangtua (*parent*), setelah dua buah individu yang akan menjadi induk terpilih selanjutnya dilakukan *crossover* untuk mendapatkan keturunan yang baru. Prinsip dasarnya adalah bahwa “induk yang baik akan menghasilkan keturunan yang baik”, sehingga individu dengan kualitas (*fitness*) lebih baik memiliki peluang lebih besar untuk diturunkan ke generasi berikutnya. Metode seleksi yang sering digunakan yaitu mesin *roulette* (*Roulette-Wheel*).

Menurut Cerf (2017), *Roulette Wheel Selection* (RWS) merupakan metode seleksi populer dalam Algoritma Genetika (GA), di mana setiap kromosom memiliki peluang untuk dipilih berdasarkan nilai *fitness* mereka. Kelebihan dari RWS termasuk kesederhanaan dalam implementasi serta efisiensi dalam penggunaan sumber daya komputasi. Namun, ada kelemahan seperti sensitivitas terhadap *noise* pada data *fitness* dan risiko konvergensi prematur pada solusi lokal. Individu dengan nilai *fitness* yang tinggi memiliki peluang lebih besar untuk dipilih, sementara individu dengan nilai *fitness* yang rendah memiliki peluang yang lebih kecil. Untuk menerapkan metode ini, diperlukan perhitungan nilai *fitness* relatif dan nilai *fitness* kumulatif dari seluruh individu dalam populasi (Whardhana et al., 2024).

Pada problem seperti *Mean Absolute Percentage Error* (MAPE), semakin kecil nilai *fitness*, maka semakin baik solusinya. Namun, dalam algoritma genetika, pemilihan individu berdasarkan probabilitas relatif menggunakan fungsi *fitness* dalam bentuk *maximization problem* (semakin besar semakin baik). Oleh karena itu, nilai

si terlebih dahulu. Secara umum, rumus peluang pemilihan $P[i]$ ditentukan menggunakan Persamaan 19 sebagai berikut to, 2022):

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



$f[i]$: Nilai *fitness* dari kromosom ke- i
 $\sum f$: Jumlah total nilai *fitness* dari seluruh kromosom

Namun, karena MAPE bersifat *minimization* (semakin kecil semakin baik), maka nilai *fitness* perlu dikonversi menggunakan fungsi inversi pada Persamaan 20.

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

Dengan,

$F'[i]$: Nilai *fitness* hasil inversi
 $f[i]$: Nilai *fitness* dari kromosom ke- i

Setelah dikonversi, probabilitas relatif dihitung berdasarkan nilai *fitness* hasil inversi, menggunakan Persamaan 21.

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

Dengan $\sum F'$ adalah Total nilai *fitness* yang telah dibalik dari seluruh kromosom. Setelah mendapatkan probabilitas relatif untuk setiap individu, dilakukan perhitungan probabilitas kumulatif untuk keperluan pemilihan menggunakan *roulette wheel selection*, menggunakan Persamaan 22 sebagai berikut:

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

Dengan,

$C[i]$: Probabilitas kumulatif individu ke- i
 $P[i]$: probabilitas relatif individu ke- i


Setelah menghitung probabilitas kumulatif, langkah berikutnya adalah membangkitkan bilangan acak R_i dengan $\{R_i \in R | 0 < R_i < 1, i = 1, 2, \dots, N\}$. Pemilihan induk dilakukan dengan membandingkan R_i terhadap nilai probabilitas kumulatif. Jika $R_i < C_i$ maka kromosom pertama dipilih sebagai induk. Sementara itu, jika $C[i - 1] < R_i < C_i$ pilih kromosom ke- i sebagai induk.

1.4.4.5 Crossover

Crossover (Pindah silang) adalah operator algoritma genetika yang melibatkan dua induk dalam pembentukan kromosom baru yang mewarisi sifat-sifat induknya.



menghasilkan keturunan yang lebih baik. *Crossover* akan terjadi dalam ruang pencarian yang siap diuji. Hal ini tidak selalu menghasilkan individu yang lebih baik. Metode yang digunakan adalah *One Point Crossover*, yaitu sebuah titik tertentu dipilih untuk pertukaran gen (Permata et al.,




Gambar 3. Ilustrasi One Point Crossover

Gambar 3 menampilkan ilustrasi *one-point crossover*, yaitu salah satu teknik rekombinasi dalam *Genetic Algorithm* yang dilakukan dengan cara menentukan satu titik potong pada urutan kromosom secara acak. Pada ilustrasi tersebut, 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*, yang diharapkan mampu mewarisi sifat-sifat unggul dari masing-masing induk dan meningkatkan kualitas solusi pada generasi selanjutnya (Fajrin, 2021).

1.4.4.6 Mutasi

Mutasi merupakan salah satu operator penting dalam *Genetic Algorithm* selain *crossover*. Tujuan utama mutasi adalah menjaga keragaman genetika dalam populasi, sehingga algoritma terhindar dari *premature convergence*, yaitu kondisi ketika seluruh populasi terjebak pada solusi lokal dan kehilangan potensi untuk menemukan solusi global. Mutasi dilakukan dengan mengubah nilai satu atau lebih gen dalam kromosom secara acak berdasarkan probabilitas mutasi tertentu (*mutation rate*). Mutasi berperan penting dalam memastikan bahwa *Genetic Algorithm* tidak hanya mengeksplorasi solusi yang sudah ada, tetapi juga terus mengeksplorasi kemungkinan baru untuk memperoleh hasil yang lebih optimal. Metode yang digunakan pada tahap ini adalah *Bit Flip Mutation*.



Gambar 4. Ilustrasi Bit Flip Mutation

Gambar 4 menampilkan ilustrasi *bit flip mutation*, yaitu salah satu teknik mutasi paling sederhana dan umum digunakan dalam kromosom biner. Tujuannya adalah memperkenalkan variasi baru ke dalam populasi agar algoritma tidak terjebak pada solusi suboptimal. Proses ini bekerja dengan cara memilih satu atau lebih kromosom secara acak, lalu dilakukan pembalikan nilai dengan 1 atau sebaliknya. Mutasi berfungsi memperkenalkan variasi yang tidak dapat dihasilkan hanya melalui proses *crossover*. Mutasi meningkatkan kemampuan populasi dalam menjelajahi ruang pencarian untuk memperbaiki peluang ditemukannya solusi optimal pada generasi selanjutnya (Simanjuntak et al., 2024).



1.4.4.7 Populasi Baru

Proses penggantian individu yang memiliki nilai *fitness* paling besar akan digantikan oleh *offspring*. Pada proses ini akan dilakukan terus menerus sampai pada suatu populasi berisi individu yang terbaik. Proses ini kemudian diulang mulai dari tahap seleksi hingga jumlah generasi yang telah ditentukan terpenuhi. Stabilitas nilai *fitness* pada generasi akhir menjadi indikator bahwa algoritma telah mencapai konvergensi.

1.4.5 Ukuran Ketepatan Nilai Peramalan

Evaluasi ketepatan hasil peramalan dapat dilakukan menggunakan beberapa ukuran akurasi, di antaranya *Mean Absolute Percentage Error* (MAPE) dan koefisien korelasi *pearson*. MAPE digunakan untuk mengukur besar rata-rata kesalahan relatif antara nilai aktual dan nilai hasil peramalan, sedangkan korelasi Pearson digunakan untuk melihat kekuatan hubungan linier antara kedua nilai tersebut. Kedua ukuran ini saling melengkapi dalam menilai performa model peramalan secara kuantitatif dan struktural. MAPE dihitung dengan mengambil rata-rata dari persentase kesalahan *absolut* antara nilai aktual dan hasil prediksi. Rumus MAPE dituliskan pada Persamaan 23 sebagai berikut (Tauryawati & Irawan, 2014).

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

Dengan:

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

Kriteria nilai kelayakan MAPE dapat dikategorikan berdasarkan rentang nilai tertentu, seperti yang ditunjukkan pada tabel berikut.

Tabel 1. Kriteria MAPE

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

Tabel 1 menunjukkan nilai MAPE dapat diinterpretasikan sebagai sangat baik jika kurang dari 10%, baik jika berada dalam rentang 10-20%, cukup baik untuk rentang 20-50%, dan buruk jika lebih dari 50%. Interpretasi ini membantu dalam menilai keakuratan model peramalan yang digunakan (Nurvianti dkk., 2019).



koefisien korelasi *pearson* (r) menunjukkan sejauh mana hubungan aktual dan hasil peramalan. Rumus korelasi Pearson dituliskan Persamaan 24 (Windarto, 2020).

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

Dengan:

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	: Banyaknya 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.

1.4.6 Produksi Kopi

Kopi merupakan komoditas unggulan subsektor perkebunan yang berperan penting sebagai sumber devisa negara, pendapatan petani, bahan baku industri, serta penyedia lapangan kerja melalui pengolahan, pemasaran, dan perdagangan (Nasirudin et al., 2022). Indonesia menempati peringkat kedua produsen kopi terbesar di Asia dan Oseania setelah Vietnam, dengan produksi mencapai 12 juta karung berukuran 60 kg pada 2022/2023, sekaligus termasuk 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 kembali turun menjadi 760.192 ton pada 2023, yang mencerminkan fluktuasi akibat faktor seperti perubahan iklim ekstrem, serangan hama, dan dinamika pasar. Ketidakpastian ini menyulitkan pemenuhan pasar, manajemen stok, dan strategi distribusi, sehingga berpotensi memengaruhi stabilitas ekonomi di daerah sentra produksi kopi (Djazuli et al., 2024).



BAB II METODOLOGI PENELITIAN

2.1 Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari situs resmi Badan Pusat Statistik (BPS) melalui laman <https://www.bps.go.id/id>. Data yang digunakan adalah Jumlah Produksi Kopi (ton) Indonesia pada periode Januari 2016 hingga Desember 2023 dengan total 96 observasi. Rincian data lengkap disajikan pada Lampiran 1.

2.2 Metode Analisis Data

Metode yang digunakan pada penelitian ini adalah *Triple Exponential Smoothing Holt-Winters* dengan optimasi *Genetic Algorithm* untuk mengetahui peramalan dari produksi kopi. Analisis data dilakukan menggunakan *software Rstudio* dan *Microsoft Excel*. Langkah analisis data yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Menyajikan statistika deskriptif dan plot deret waktu jumlah produksi kopi Indonesia.
2. Mengidentifikasi pola musiman (aditif atau multipikatif) pada data.
3. Membagi data menjadi tiga bagian, yaitu 12 data (Januari 2016-Desember 2016) digunakan sebagai data *training* untuk penentuan nilai awal *Smoothing*, 72 data (Januari 2016-Desember 2022) digunakan sebagai data *training* untuk penentuan parameter optimal, dan 12 data (Januari 2023-Desember 2023) digunakan sebagai data *testing*.
4. Melakukan peramalan produksi kopi dari data *training* menggunakan metode *Triple Exponential Smoothing Holt-Winter's*:
 - a. Menginisialisasi nilai awal: *Smoothing level* (Persamaan 7), faktor tren (Persamaan 8), faktor musiman untuk aditif (Persamaan 9), dan faktor musiman untuk multiplikatif (Persamaan 10).
 - b. Menentukan parameter awal (α), (β), dan (γ) yang akan dengan syarat $0 < \alpha < 1$, $0 < \beta < 1$, dan $0 < \gamma < 1$ melalui proses *trial and error*, sehingga diperoleh nilai parameter awal α sebesar 0,1; β sebesar 0,2; dan γ sebesar 0,3.
 - c. Membuat fungsi peramalan menggunakan *Triple Exponential Smoothing Holt-Winters* pendekatan aditif dan melakukan peramalan pada masing-masing parameter α , β , dan γ menggunakan Persamaan 11-14.
 - d. Membuat fungsi peramalan menggunakan *Triple Exponential Smoothing*



s pendekatan multiplikatif dan melakukan peramalan pada
sing parameter α , β , dan γ menggunakan Persamaan 15-18.
i MAPE berdasarkan hasil peramalan dan data *testing* dari
Exponential Smoothing Holt-Winters pada setiap pendekatan.
nasi parameter menggunakan metode *Genetic Algorithm*:
n pembentukan kromosom dengan representasi biner dari
parameter (α), (β), dan (γ) yang berada pada rentang

syarat $0 < \alpha < 1$, $0 < \beta < 1$, dan $0 < \gamma < 1$ dengan nilai presisi parameter sebenar 10^{-4} .

- b. Membangkitkan populasi awal sebanyak 10 kromosom.
 - c. Menghitung nilai *fitness* $f(y)$ dari setiap kromosom dalam populasi.
 - d. Melakukan penyesuaian nilai *fitness* melalui proses inversi, di mana semakin kecil MAPE, semakin besar nilai *fitness* hasil inversi (Persamaan 19) yang digunakan dalam proses seleksi.
 - e. Menghitung nilai probabilitas relatif dari setiap kromosom (Persamaan 20), serta menghitung nilai probabilitas kumulatif (Persamaan 21).
 - f. Melakukan proses seleksi menggunakan metode *Roulette Wheel Selection*, dengan menghasilkan bilangan acak antara 0 hingga 1.
 - g. Melakukan proses *crossover* terhadap dua kromosom induk terpilih menggunakan metode *one point crossover*.
 - h. Melakukan proses mutasi terhadap kromosom hasil *crossover* menggunakan metode *bit flip mutation*.
 - i. Menempatkan keturunan baru pada populasi.
 - j. Mengganti populasi lama dengan populasi baru yang telah dihasilkan melalui proses seleksi, *crossover*, dan mutasi untuk digunakan pada iterasi selanjutnya.
 - k. Mengevaluasi kondisi terminasi algoritma; apabila kondisi akhir telah terpenuhi, maka proses dihentikan dan mutasi terbaik pada populasi disimpan sebagai hasil akhir.
 - l. Jika kondisi akhir belum terpenuhi, algoritma dilanjutkan kembali ke tahap seleksi dan diulangi hingga mencapai kondisi terminasi.
 - m. Memilih kombinasi parameter *Smoothing* yang optimal berdasarkan nilai MAPE yang terkecil.
7. Melakukan beberapa percobaan untuk mengevaluasi kinerja metode, yaitu:
- a. Memvariasikan ukuran populasi pada algoritma genetika dengan nilai 10, 20, 30, 40, dan 50.
 - b. Mengombinasikan nilai *crossover rate* dan *mutation rate* dalam 10 skenario percobaan.
 - c. Menguji jumlah generasi dengan variasi nilai 10 hingga 100.
 - d. Mengevaluasi tingkat akurasi peramalan berdasarkan hasil variasi parameter yang digunakan.
 - e. Menentukan konfigurasi parameter terbaik yang menghasilkan tingkat akurasi paling optimal.



malan produksi kopi Indonesia untuk 12 bulan ke depan yaitu 3 menggunakan *Holt-Winters Triple Exponential Smoothing Genetic Algorithm*.