

# PERAMALAN TINGKAT INFLASI DI INDONESIA MENGGUNAKAN *ARTIFICIAL BEE COLONY* DAN XGBOOST

Farrel Adel Mohammad<sup>1</sup>, Agung Mustika Rizki<sup>2</sup>, Andreas Nugroho Sihananto<sup>3</sup>

<sup>1,2,3</sup>Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

Received: 10 Juli 2024

Accepted: 31 Juli 2024

Published: 7 Agustus 2024

## Keywords:

*Forecasting, Inflation, XGBoost, Optimization Algorithm, Artificial bee colony*

## Correspondent Email:

20081010138@student.upnjatim.ac.id  
agung.mustika.if@upnjatim.ac.id  
andreas.nugroho.jarkom@upnjatim.ac.id

**Abstrak.** Pertumbuhan ekonomi dan stabilitas harga merupakan fokus utama bagi negara-negara, termasuk Indonesia. Inflasi, sebagai indikator fluktuasi harga barang dan jasa, memainkan peran penting dalam stabilitas ekonomi. Peramalan inflasi menjadi kunci bagi pemerintah dan pemangku kepentingan ekonomi untuk merancang kebijakan yang responsif. Model pembelajaran mesin, seperti XGBoost, telah digunakan untuk tujuan ini, namun penyetelan hiperparameter yang optimal menjadi kunci keberhasilannya. Algoritma optimisasi seperti *Artificial bee colony* (ABC) dapat mengotomasi proses penyetelan hiperparameter XGBoost, meningkatkan efisiensi dan kinerja model. Penelitian ini membuktikan bahwa kombinasi *Artificial bee colony* dan XGBoost berhasil meramalkan tingkat inflasi bulanan di Indonesia dengan hasil yang akurat. Implementasi metode ini memberikan rata-rata skor RMSE 0.155066, skor MAE 0.115655, dan skor MAPE 0.795767.

**Abstract.** Economic growth and price stability are the main focus for countries, including Indonesia. Inflation, as an indicator of fluctuations in the prices of goods and services, plays an important role in economic stability. Inflation forecasting is key for governments and economic stakeholders to design responsive policies. Machine learning models, such as XGBoost, have been used for this purpose, but optimal hyperparameter tuning is key to its success. Optimization algorithms such as *Artificial bee colony* (ABC) can automate the hyperparameter tuning process of XGBoost, improving the efficiency and performance of the model. This research proves that the combination of *Artificial bee colony* and XGBoost can successfully forecast the monthly inflation rate in Indonesia with accurate results. The implementation of this method gives an average RMSE score of 0.155066, MAE score of 0.115655, and MAPE score of 0.795767.

## 1. PENDAHULUAN

Pertumbuhan ekonomi adalah indikator utama kesuksesan pembangunan suatu negara, termasuk Indonesia. Stabilitas harga, yang diukur melalui inflasi, sangat penting untuk menjaga kestabilan ekonomi. Inflasi yang tidak terkendali dapat merusak kesejahteraan

masyarakat dan kestabilan ekonomi secara keseluruhan [1].

Peramalan inflasi menjadi instrumen penting bagi pemerintah dan pemangku kepentingan ekonomi untuk membuat kebijakan yang tepat dan responsif. Para investor dan pelaku industri juga membutuhkan prediksi inflasi yang akurat untuk pengambilan

keputusan yang bijak [2]. Teknik peramalan yang menggunakan data historis telah berkembang pesat, terutama dengan kemajuan dalam bidang pembelajaran mesin. Model seperti XGBoost, yang dikembangkan oleh Chen dan He pada tahun 2015. Model ini memiliki keunggulan dalam hal efisiensi dan skalabilitasnya [3].

XGBoost adalah model ensemble yang menggabungkan implementasi pohon keputusan yang efisien untuk menghasilkan model gabungan dengan kinerja prediktif yang lebih unggul dibandingkan teknik individu yang digunakan secara terpisah [4]. XGBoost mampu menangani berbagai jenis pembelajaran, mulai dari klasifikasi hingga regresi. Namun, model XGBoost sangat bergantung terhadap bagaimana hiperparameter diatur, pengaturan yang optimal akan menghasilkan model yang baik [5]. Penyetelan hiperparameter yang tepat sangat penting untuk memaksimalkan kinerja model. Walaupun XGBoost menawarkan fleksibilitas tinggi dalam menentukan hiperparameter, proses penyetelannya seringkali rumit dan memakan waktu. Di sinilah peran algoritma optimasi seperti *Artificial bee colony* (ABC) menjadi relevan.

Algoritma *Artificial bee colony* (ABC) memberikan pendekatan menarik untuk optimasi hiperparameter. Terinspirasi dari perilaku lebah dalam mencari sumber makanan, ABC mengatur populasi lebah yang terdiri dari tiga kelompok dengan peran berbeda-beda [6]. Lebah pekerja mencari dan memberikan informasi tentang sumber makanan kepada lebah pengamat, yang kemudian memilih sumber makanan untuk dieksplorasi. Sementara itu, lebah pengintai bertugas mencari sumber makanan baru secara acak. Proses iteratif ini memungkinkan ABC untuk menemukan konfigurasi hiperparameter yang optimal untuk model XGBoost.

Penelitian ini bertujuan mengeksplorasi kemampuan ABC-XGBoost dalam permasalahan regresi yaitu meramalkan tingkat inflasi di Indonesia. Hasil penelitian ini diharapkan memberikan wawasan tambahan pada pengembangan metodologi peramalan inflasi serta kontribusi praktis bagi pembuat kebijakan, analis pasar, dan pemangku kepentingan ekonomi lainnya. Dengan pemahaman yang lebih baik tentang tren inflasi dan penggunaan model peramalan yang lebih

efisien, kebijakan moneter yang lebih responsif dan efektif dapat dirumuskan.

## 2. TINJAUAN PUSTAKA

Mengakses dan memahami penelitian sebelumnya sangat penting untuk pengembangan penelitian baru. Merujuk pada karya-karya terdahulu membantu menemukan ide-ide yang relevan, teori yang telah teruji, dan metode yang efektif. Hal ini juga membantu peneliti mengidentifikasi celah penelitian serta memahami keunggulan dan kelemahan pendekatan yang digunakan sebelumnya.

Penelitian sebelumnya menyediakan landasan untuk memberikan saran dan rekomendasi bagi penelitian selanjutnya. Memahami penelitian terdahulu memungkinkan peneliti mengusulkan perbaikan, pengembangan, atau pendekatan baru yang lebih relevan. Oleh karena itu, tahap mempelajari penelitian sebelumnya menjadi langkah penting dalam proses penelitian.

### 2.1 Inflasi

Inflasi pada dasarnya mencerminkan ketidakseimbangan antara penawaran dan permintaan dalam perekonomian nasional [7]. Tingkat inflasi yang tinggi sering kali dikaitkan dengan kondisi perekonomian yang terlalu aktif atau "overheated". Hal ini mengindikasikan bahwa permintaan atas produk melebihi kapasitas produksi yang tersedia, sehingga menyebabkan kenaikan harga-harga [8]. Jika jumlah uang yang beredar meningkat sementara pengeluaran pemerintah dan suku bunga menurun, maka inflasi di Indonesia akan meningkat. Sebaliknya, jika jumlah uang yang beredar menurun sementara pengeluaran pemerintah dan suku bunga meningkat, maka inflasi di Indonesia akan menurun [9].

### 2.2 Peramalan

Peramalan adalah proses membuat prediksi tentang masa depan berdasarkan data masa lalu dan saat ini, yang sering dilakukan dengan menganalisis pola tren. Contoh umumnya adalah memperkirakan nilai suatu variabel tertentu pada waktu tertentu di masa depan [10]. Peramalan merupakan upaya untuk memproyeksikan kondisi di masa mendatang berdasarkan evaluasi masa lalu [11]. Peramalan atau prediksi menggabungkan keahlian dan pengetahuan untuk memproyeksikan kejadian

masa depan dengan menggunakan data masa lalu dan berbagai model matematis [12]. Oleh karena itu, peramalan atau *forecasting* memiliki peran krusial dalam penelitian ini untuk memprediksi tingkat inflasi di Indonesia di masa mendatang dengan memanfaatkan data historis yang telah terkumpul.

### 2.3 XGBoost

XGBoost adalah teknik pembelajaran yang diawasi yang menawarkan efisiensi, adaptabilitas, dan portabilitas luar biasa. Menggunakan algoritma pembelajaran otomatis dalam kerangka kerja Gradient Boosting, XGBoost memberikan peningkatan pohon paralel yang cepat dan efektif untuk menangani berbagai tantangan dalam ilmu data. Keunggulan utamanya meliputi skalabilitas yang tinggi, eksekusi yang cepat, dan kinerja superior dibandingkan dengan algoritma lain [13]. Hiperparameter memegang peranan penting dalam mengoptimalkan kinerja model XGBoost. Dengan mengatur parameter ini, pengguna dapat memperbaiki cara algoritma beroperasi untuk mencapai hasil yang lebih baik dalam pengolahan data dan prediksi yang mereka lakukan [5].

### 2.4 Algoritma Optimasi

Optimasi adalah usaha untuk mencapai hasil terbaik dalam suatu masalah keputusan, mempertimbangkan keterbatasan sumber daya yang tersedia [14]. Peran optimasi dalam pembelajaran mesin sangat signifikan karena dapat meningkatkan kinerja model dan kemampuannya untuk generalisasi. Pemilihan metode optimasi memiliki dampak yang besar dalam berbagai aspek pembelajaran mesin, termasuk teknik yang diawasi maupun tidak [15]. Dengan kata lain, teknik optimasi digunakan untuk meningkatkan akurasi dan efektivitas model pembelajaran mesin, sehingga mereka dapat menangani masalah yang kompleks dengan lebih efisien [16].

### 2.5 Artificial bee colony (ABC)

Algoritma *Artificial bee colony* (ABC), terinspirasi dari perilaku lebah dalam mencari sumber makanan, merupakan metode optimisasi untuk fungsi numerik yang kompetitif dan terkini. Koloni ABC terdiri dari tiga kelompok utama: lebah pekerja, pengamat, dan penjelajah. Pekerja mengeksplorasi nektar

dan memberi informasi kepada pengamat untuk memilih sumber makanan optimal. Penjelajah mencari sumber makanan baru secara acak. Proses ini diulang hingga kondisi berhenti tercapai atau mencapai batas generasi maksimum (MaxGen). Solusi dalam ABC dinyatakan oleh posisi sumber [6]. ABC digunakan untuk mengoptimalkan berbagai fungsi uji numerik dengan hasil yang setara atau lebih baik dibandingkan dengan algoritma lain seperti genetika, partikel swarm optimization, evolusi diferensial, dan strategi evolusi, namun dengan penggunaan parameter kontrol yang lebih sedikit [17].

### 2.6 Perhitungan Nilai Galat

Pengukuran nilai galat adalah pendekatan penting dalam mengevaluasi perbedaan antara nilai prediksi dan nilai aktual dari suatu model. Metode ini krusial dalam pengembangan sistem prediksi di berbagai bidang seperti pembelajaran mesin, statistik, dan ekonomi, membantu untuk meningkatkan akurasi model [18].

Root Mean Square Error (RMSE) adalah metode umum yang digunakan dalam permasalahan regresi untuk mengukur seberapa baik model memprediksi nilai aktual. RMSE menggunakan standar deviasi dari galat untuk menilai performa model [19]. Mean Absolute Percentage Error (MAPE) adalah metrik kinerja lainnya untuk model regresi yang fokus pada kesalahan relatif. MAPE berguna untuk memahami fluktuasi relatif daripada variasi absolut antara nilai prediksi dan aktual [20]. Mean Absolute Error (MAE) adalah metode lain yang digunakan untuk mengukur kesalahan absolut rata-rata antara nilai prediksi dan nilai aktual. MAE memberikan gambaran tentang seberapa besar rata-rata perbedaan absolut antara nilai prediksi dan nilai aktual [21].

### 2.7 ABC-XGBoost

ABC-XGBoost adalah metode yang mengatasi tantangan dalam mengatur hiperparameter pada algoritma XGBoost yang kompleks [22]. Menggunakan tiga koloni lebah yang bekerja secara kooperatif, ABC-XGBoost memanfaatkan informasi dari langkah-langkah sebelumnya untuk mempercepat pencapaian solusi optimal dan meningkatkan kecepatan konvergensi algoritma [23]. Fokus utama ABC adalah pada optimasi hiperparameter algoritma

XGBoost, membantu dalam mencari model optimal dengan tingkat efisiensi yang tinggi.

### 3. METODE PENELITIAN

Penelitian ini bertujuan untuk meramalkan inflasi di Indonesia dengan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) dan *Artificial bee colony* (ABC). Tahap awal dimulai dengan tinjauan literatur untuk mengidentifikasi permasalahan yang relevan dalam bidang teknologi. Ini menjadi dasar untuk merumuskan rumusan masalah penelitian. Selanjutnya, penelitian melanjutkan ke analisis dan desain, di mana peneliti merencanakan kerangka kerja dan metode penelitian yang akan digunakan.

Setelah merancang kerangka kerja, langkah berikutnya adalah pengumpulan data berkualitas yang relevan dengan permasalahan yang ingin dipecahkan. Data ini kemudian diekstraksi dan diproses untuk preprocessing, di mana peneliti menyaring dan membersihkan data untuk kesiapan penggunaan selanjutnya. Setelah itu, hiperparameter untuk model ditentukan, dan model XGBoost dioptimalkan menggunakan metode *Artificial bee colony* (ABC).

Pengujian dilakukan untuk mencari hasil yang optimal dari model yang digunakan. Akhirnya, hasil penelitian dianalisis secara mendalam untuk memberikan gambaran eksekusi dari penelitian skripsi ini, memberikan kontribusi terhadap pemahaman tentang peramalan inflasi di Indonesia.

#### 3.1 Tinjauan Literatur

Penelitian dimulai dengan mengumpulkan literatur untuk mengeksplorasi dan menganalisis isu-isu dalam teknologi. Tinjauan literatur membantu memahami metodologi dan terminologi yang tidak dikenal, sambil mengidentifikasi kesenjangan dalam penelitian yang ada dan mempertimbangkan pendekatan untuk desain sistem. Tahap ini sangat penting dalam proses penelitian.

#### 3.2 Analisa dan Desain

Penulis melakukan analisis mendalam dan merancang desain sistem. Desain sistem ini mencakup proses pengumpulan data, preprocessing data, menentukan hiperparameter yang digunakan, melakukan optimasi hiperparameter XGBoost dengan *Artificial bee*

*colony*, melakukan pengujian, hingga menganalisa hasil. Dengan tahapan-tahapan tersebut, dapat dilakukan penelitian terkait meramalkan tingkat inflasi di Indonesia menggunakan *Artificial bee colony* dan XGBoost.

#### 3.3 Pengumpulan Data

Pengumpulan data dilakukan dengan dua cara. Data diunduh dari halaman website Badan Pusat Statistik yang meliputi data inflasi bulanan dan inflasi tahunan. Kemudian, juga dilakukan pengumpulan data dengan cara scraping dari halaman website BPS. Data-data yang melalui proses scraping diantaranya: Indeks Harga Konsumen, tingkat suku bunga, jumlah uang beredar M1, jumlah uang beredar M2, volume saham, nilai saham, dan Indeks Harga Saham Komposit.

#### 3.4 Preprocessing Data

Setelah data terkumpul, tahap berikutnya adalah preprocessing data. Proses ini mencakup beberapa langkah penting untuk mempersiapkan data sebelum digunakan dalam pembentukan model. Tahapan termasuk normalisasi data, yang melibatkan konversi teks seperti nama bulan dari Bahasa Indonesia ke Bahasa Inggris untuk kolom tanggal. Selanjutnya, data yang sudah dinormalisasi direshape untuk memastikan format yang sesuai dengan kebutuhan analisis, termasuk perubahan format data ke tipe yang sesuai seperti tanggal dan float untuk pecahan. Kemudian membersihkan data dari nilai NaN yang mungkin muncul, memastikan data bersih dan siap digunakan. Selanjutnya, penambahan fitur dilakukan untuk meningkatkan kualitas data, seperti menambahkan fitur lag untuk memperkirakan nilai inflasi berdasarkan nilai sebelumnya. Kemudian terdapat fitur dari tanggal, yang akan mengekstraksi tahun dan kuartal bulan pada tahun. Selain itu, terdapat fitur statistik bergulir untuk tiga bulan terakhir.

#### 3.5 Penentuan Hiperparameter

Pada tahap ini, akan ditentukan hiperparameter yang akan digunakan dalam proses optimasi. Hal ini meliputi jenis hiperparameter yang dipilih serta nilai-nilai spesifik yang akan diatur untuk masing-masing hiperparameter tersebut. Contoh dari penentuan ini dapat dilihat dalam tabel berikut, yang

mengilustrasikan hiperparameter beserta nilai-nilai yang dipilih untuk mengoptimalkan model yang digunakan.

**Tabel 1 Set Hiperparameter**

| Hiperparameter       | Set Nilai                        |
|----------------------|----------------------------------|
| <i>n_estimators</i>  | [100, 200, 300, 500]             |
| <i>learning_rate</i> | [0.001, 0.01, 0.05, 0.1, 0.5, 1] |
| <i>max_depth</i>     | [3, 6, 9]                        |
| <i>gamma</i>         | [0.01, 0.1]                      |

### 3.6 ABC-XGBoost

Pada tahap ini, sistem akan mengimplementasikan optimasi hiperparameter XGBoost menggunakan metode *Artificial bee colony* (ABC). Proses dimulai dengan inialisasi algoritma ABC dan berlanjut dengan fase-fase seperti lebah pekerja, lebah pengamat, dan lebah pengintai yang berfokus pada eksplorasi solusi hiperparameter yang lebih baik berdasarkan nilai RMSE dari model XGBoost.

Evaluasi *fitness* dilakukan untuk mengevaluasi kinerja solusi hiperparameter. Ini meliputi pelatihan model XGBoost dengan hiperparameter yang diajukan, diikuti dengan pengujian untuk menghitung RMSE. Data dibagi menjadi set latih dan uji, dengan fitur-fitur yang digunakan untuk memprediksi target yang telah ditentukan.

Pada tahap inialisasi, parameter algoritma ditentukan seperti jumlah populasi, iterasi maksimum, dan hiperparameter yang ingin dioptimalkan. Populasi awal lebah (representasi hiperparameter) diinisialisasi secara acak, diikuti dengan perhitungan *fitness* untuk setiap solusi.

Fase lebah pekerja melibatkan eksplorasi tetangga dari solusi awal, dimana hiperparameter sedikit dimodifikasi untuk mencari solusi dengan *fitness* lebih baik. Fase lebah pengamat akan melakukan eksplorasi terhadap lebah berdasarkan probabilitas. Akan dilakukan eksplorasi tetangga terhadap lebah terpilih. Fase lebah pengintai berperan ketika solusi mengalami stagnasi, dengan pembuatan solusi baru secara acak untuk melanjutkan eksplorasi. Kriteria berhenti diimplementasikan untuk mengakhiri proses optimasi, berdasarkan jumlah iterasi yang telah ditentukan dalam algoritma ABC.

### 3.7 Pengujian

Tahap selanjutnya adalah pengujian, di mana dilakukan penyetelan terhadap algoritma *Artificial bee colony* (ABC) untuk mencari konfigurasi optimal. Berbagai skenario pengujian ditetapkan untuk mengevaluasi kinerja ABC dalam mencari model terbaik, seperti variasi jumlah lebah, jumlah generasi, dan pembagian data latih dan uji.

Setelah pengujian selesai, hasilnya berupa model untuk setiap konfigurasi yang dievaluasi menggunakan metrik seperti RMSE, MAE, dan MAPE. Metrik-metrik ini digunakan untuk menilai kehandalan model ABC-XGBoost dalam meramalkan inflasi di Indonesia.

## 4. HASIL DAN PEMBAHASAN

### 4.1 Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data dari website BPS yang sudah di scraping. Berikut merupakan informasi terkait data yang akan dilakukan scraping. Data yang discraping seperti Indeks Harga Konsumen (IHK), BI Rate, Volume dan Nilai Bursa Efek, serta data uang beredar dari situs web BPS Indonesia. Data inflasi bulan ke bulan dan tahun ke tahun diunduh secara manual untuk memastikan keakuratan.

Tingkat Inflasi Harga Konsumen Nasional Tahunan (Y-on-Y) (2022=100)

| Bulan     | 2006  | 2007 | 2008  | 2009 | 2010 | 2011 | 2012 | 2013 | 2014 | 2015 | 2016 | 2017 | 2018 |
|-----------|-------|------|-------|------|------|------|------|------|------|------|------|------|------|
| Januari   | 17,01 | 6,26 | 7,26  | 9,57 | 9,72 | 7,02 | 9,95 | 4,57 | 6,22 | 6,36 | 4,21 | 3,45 | 8,2  |
| Februari  | 17,92 | 6,30 | 7,40  | 8,80 | 9,81 | 6,84 | 9,56 | 5,31 | 7,75 | 6,28 | 4,42 | 3,81 | 9,1  |
| Maret     | 15,74 | 6,32 | 8,17  | 7,50 | 9,43 | 6,85 | 9,97 | 5,90 | 7,32 | 6,38 | 4,45 | 3,61 | 9,4  |
| April     | 15,40 | 6,29 | 8,96  | 7,51 | 9,91 | 6,18 | 9,50 | 5,57 | 7,25 | 6,79 | 3,89 | 4,17 | 9,4  |
| Mei       | 15,80 | 6,01 | 10,38 | 6,06 | 4,38 | 9,98 | 4,40 | 5,47 | 7,32 | 7,10 | 3,39 | 4,31 | 9,2  |
| Juni      | 15,53 | 5,77 | 11,03 | 3,85 | 5,05 | 5,54 | 4,53 | 5,90 | 6,70 | 7,26 | 3,45 | 4,37 | 9,1  |
| Juli      | 15,15 | 6,06 | 11,90 | 2,71 | 6,22 | 4,61 | 4,58 | 6,61 | 4,53 | 7,26 | 3,21 | 3,88 | 9,1  |
| Agustus   | 14,90 | 6,31 | 11,85 | 2,79 | 6,44 | 4,79 | 4,58 | 6,79 | 3,99 | 7,18 | 2,79 | 3,82 | 9,2  |
| September | 14,53 | 6,95 | 12,14 | 2,83 | 5,80 | 4,61 | 4,31 | 8,40 | 4,53 | 6,80 | 3,07 | 3,72 | 2,8  |
| Oktober   | 6,29  | 6,88 | 11,77 | 2,57 | 5,87 | 4,42 | 4,61 | 8,32 | 4,83 | 6,25 | 3,31 | 3,58 | 9,1  |
| November  | 5,27  | 6,71 | 11,68 | 2,41 | 6,33 | 4,15 | 4,52 | 8,37 | 6,23 | 6,89 | 3,58 | 3,30 | 9,2  |
| Desember  | 6,60  | 6,59 | 11,06 | 2,78 | 6,96 | 3,79 | 4,30 | 8,38 | 6,36 | 5,05 | 3,02 | 3,61 | 9,1  |

**Gambar 1 Data Unduh**

Proses scraping data dilakukan menggunakan Python dengan bantuan modul BeautifulSoup dan Selenium. Selenium digunakan untuk mengotomatiskan interaksi dengan halaman web yang memerlukan input atau klik tombol, sementara BeautifulSoup digunakan untuk parsing HTML dan ekstraksi data. Data yang berhasil diambil dari proses scraping dikonversi menjadi Pandas DataFrame. Langkah ini dilakukan dengan menambahkan tanggal ke data yang telah diambil, sehingga siap digunakan untuk analisis lebih lanjut. Hasil akhir dari proses ini disimpan dalam format CSV untuk memudahkan akses dan penggunaan data di masa mendatang.

|     | INDONESIA | BI Rate | Jumlah (M1)  | Jumlah (M2)  | Volume (Juta Saham) | Nilai (Milyar Rp) | Indeks Harga Saham Komposit | date       |
|-----|-----------|---------|--------------|--------------|---------------------|-------------------|-----------------------------|------------|
| 0   | 118,01    | 6,5     | 490.083,79   | 2.066.400,99 | 86.348              | 79.012            | 2.610,8                     | 2010-01-01 |
| 1   | 118,36    | 6,5     | 494.460,84   | 2.112.082,7  | 76.400              | 63.556            | 2.540,03                    | 2010-02-01 |
| 2   | 118,19    | 6,5     | 494.717,69   | 2.116.023,54 | 97.681              | 104.136           | 2.777,3                     | 2010-03-01 |
| 3   | 118,37    | 6,5     | 514.005,04   | 2.143.234,05 | 119.513             | 110.461           | 2.971,25                    | 2010-04-01 |
| 4   | 118,71    | 6,5     | 545.405,37   | 2.231.144,33 | 111.216             | 96.959            | 2.796,96                    | 2010-05-01 |
| ... | ...       | ...     | ...          | ...          | ...                 | ...               | ...                         | ...        |
| 163 | 115,22    | 5,75    | 2.410.850,87 | 8.364.739    | 427.799             | 246.353           | 6.953,26                    | 2023-08-01 |
| 164 | 115,44    | 5,75    | 2.482.229,03 | 8.441.236,44 | 438.654             | 227.256           | 6.939,89                    | 2023-09-01 |
| 165 | 115,64    | 6       | 2.497.710,3  | 8.506.544,06 | 435.790             | 228.413           | 6.752,21                    | 2023-10-01 |
| 166 | 116,08    | 6       | 2.510.759,32 | 8.574.917,1  | 448.917             | 244.214           | 7.080,74                    | 2023-11-01 |
| 167 | 116,56    | 6       | 2.675.333,28 | 8.826.531    | 520.610             | 249.464           | 7.272,8                     | 2023-12-01 |

168 rows x 9 columns

Gambar 2 Hasil Scraping

## 4.2 Preprocessing Data

Tahap ini memproses data yang telah dikumpulkan sebelumnya untuk memudahkan pembentukan model pada tahap selanjutnya. Operasi preprocessing dilakukan seperti merubah tipe data, mengubah bentuk data, dan merubah nama kolom, serta menggabungkan data yang sudah dikumpulkan.

Pertama, data inflasi bulanan, tahunan, dan hasil scraping dibaca menggunakan fungsi pada library Pandas. Setelah data dibaca, nama bulan dalam Bahasa Indonesia diubah menjadi Bahasa Inggris. Ini memungkinkan persiapan data untuk tahap preprocessing lanjutan.

Data inflasi diubah menjadi time series yang mengubah struktur data dari lebar menjadi panjang, memfasilitasi analisis time series lebih lanjut. Selanjutnya, DataFrame inflasi bulanan dan tahunan digabungkan menjadi satu DataFrame dengan fungsi merge. Hasilnya, DataFrame ini digabungkan dengan DataFrame hasil scraping untuk mempersiapkan data untuk analisis selanjutnya.

Data final kemudian diindeks berdasarkan tanggal dan semua kolom yang memiliki tipe data objek diubah menjadi float64 untuk memungkinkan perhitungan numerik. Terakhir, nama kolom diubah untuk mempermudah pengembangan model pada tahap selanjutnya, dan data time series diubah menjadi *supervised learning* dengan menggeser kolom inflasi bulanan.

## 4.3 Penambahan Fitur

Tahap ini krusial dalam pembentukan model, di mana fokusnya adalah menciptakan fitur baru dan memodifikasi fitur yang ada dalam data. Salah satu teknik yang digunakan adalah menambahkan fitur lag, yang mengacu pada nilai-nilai sebelumnya dari kolom-kolom tertentu dalam DataFrame. Ini membantu model machine learning dalam memahami pola temporal dari data historis.

Fitur lag akan ditambahkan kepada dataset. Proses ini melibatkan pengulangan untuk setiap

kolom yang dipilih, dimana setiap nilai akan digeser mundur sesuai dengan jumlah langkah waktu yang ditentukan, dan kolom baru dengan nama yang sesuai akan dibuat.

Selanjutnya, ekstraksi fitur dilakukan dari kolom tanggal untuk menambahkan informasi waktu seperti tahun dan kuartal ke DataFrame. Ekstraksi fitur digunakan untuk menghasilkan kolom-kolom baru yang berisi tahun dan kuartal dari setiap tanggal yang terdaftar.

Fitur statistik bergulir juga diterapkan untuk memberikan model informasi tambahan tentang tren dan fluktuasi dalam data historis. Akan dihitung rolling mean dan rolling standard deviation dari kolom-kolom yang dipilih dengan menggunakan jendela waktu tertentu.

Penambahan fitur akan menghasilkan kolom kosong akibat tidak adanya data untuk menghasilkan nilai lag atau nilai sebelumnya. Baris yang mengandung nilai kosong dihapus dari DataFrame untuk memastikan data yang bersih dan lengkap sebelum dilanjutkan ke tahap selanjutnya.

Proses ini akan memberikan informasi yang lebih baik untuk dilakukan proses peramalan. Setelah melalui tahapan ini, jumlah kolom pada dataset mengalami peningkatan jumlah yang signifikan. Selain itu, jumlah baris dataset berkurang jumlahnya akibat penambahan fitur lag dan fitur statistik bergulir. Dengan serangkaian proses ini, DataFrame menjadi lebih kaya dengan fitur-fitur tambahan yang dapat meningkatkan performa model machine learning dalam memprediksi tren dan pola dari data yang ada.

## 4.4 Implementasi XGBoost

Tahap berikutnya adalah implementasi XGBoost yang akan dioptimalkan menggunakan algoritma *Artificial bee colony*. Akan dilakukan pembagian data menjadi set pelatihan dan pengujian, kemudian melakukan pelatihan model XGBoost dengan solusi hiperparameter yang diberikan. Prediksi dilakukan pada data pengujian dan diukur menggunakan metrik RMSE untuk mengevaluasi performa model dalam memprediksi nilai target. Dengan menggunakan pendekatan ini, pengoptimalan hiperparameter model XGBoost dengan pendekatan *Artificial bee colony* dapat dilakukan secara efisien dan efektif untuk meningkatkan kinerja prediktifnya.

#### 4.5 Optimasi Hiperparameter dengan ABC

*Artificial bee colony* (ABC) dirancang untuk meningkatkan kinerja model XGBoost. ABC akan mencari kombinasi hiperparameter bagi XGBoost secara random hingga iterasi selesai. Inisialisasi populasi digunakan untuk memulai populasi lebah dengan solusi-solusi acak. Setiap solusi dihasilkan menggunakan metode generasi solusi pada kelas XGBoost yang didefinisikan pada tahap sebelumnya, dan setiap lebah dalam populasi diberi nilai *fitness* awal dengan melakukan evaluasi pada hiperparameter.

Fase lebah pekerja dalam algoritma ABC diawali dengan Setiap lebah mencoba menghasilkan solusi tetangga dari solusi saat ini menggunakan metode dari model XGBoost. Jika solusi tetangga memiliki nilai *fitness* yang lebih baik daripada solusi saat ini, solusi dan nilai *fitness* lebah diperbarui; jika tidak, iterasi batas percobaan untuk solusi tersebut ditingkatkan.

Fase lebah pengamat dalam algoritma ABC diimplementasikan dengan setiap lebah memilih solusi untuk dievaluasi berdasarkan probabilitas yang dihitung dari *fitness* masing-masing solusi dalam populasi. Solusi dipilih secara random dengan probabilitas sesuai dengan invers dari *fitness* solusi. Setelah memilih solusi, lebah mencoba menghasilkan solusi tetangga dan mengevaluasi *fitness*nya. Jika solusi tetangga lebih baik, solusi dan nilai *fitness* lebah diperbarui; jika tidak, iterasi batas percobaan untuk solusi tersebut ditingkatkan.

Fase lebah scout, mengidentifikasi solusi yang tidak mengalami peningkatan setelah melewati batas percobaan (limit). Solusi untuk lebah-lebah ini digantikan dengan solusi acak baru menggunakan metode dari model XGBoost, dan iterasi batas percobaan serta *fitness* untuk solusi baru direset.

#### 4.6 Skema Pengujian

Pada tahap pengujian ini, dilakukan evaluasi untuk menyesuaikan algoritma *Artificial bee colony* agar menghasilkan optimalitas dalam waktu eksekusi dan metrik evaluasi seperti RMSE, MAE, dan MAPE. Pengujian dilakukan dengan mempertimbangkan variasi dalam jumlah lebah, generasi maksimum, dan pembagian data latih dan uji. Skema pengujian terdiri dari 27 kombinasi yang dievaluasi

sebanyak 10 kali percobaan untuk setiap konfigurasi.

**Tabel 2 Skema Pengujian**

| No | Populasi | Generasi | Data Latih | Data Uji |
|----|----------|----------|------------|----------|
| 1  | 10       | 10       | 90%        | 10%      |
| 2  | 10       | 10       | 80%        | 20%      |
| 3  | 10       | 10       | 70%        | 30%      |
| 4  | 10       | 15       | 90%        | 10%      |
| 5  | 10       | 15       | 80%        | 20%      |
| 6  | 10       | 15       | 70%        | 30%      |
| 7  | 10       | 20       | 90%        | 10%      |
| 8  | 10       | 20       | 80%        | 20%      |
| 9  | 10       | 20       | 70%        | 30%      |
| 10 | 30       | 10       | 90%        | 10%      |
| 11 | 30       | 10       | 80%        | 20%      |
| 12 | 30       | 10       | 70%        | 30%      |
| 13 | 30       | 15       | 90%        | 10%      |
| 14 | 30       | 15       | 80%        | 20%      |
| 15 | 30       | 15       | 70%        | 30%      |
| 16 | 30       | 20       | 90%        | 10%      |
| 17 | 30       | 20       | 80%        | 20%      |
| 18 | 30       | 20       | 70%        | 30%      |
| 19 | 50       | 10       | 90%        | 10%      |
| 20 | 50       | 10       | 80%        | 20%      |
| 21 | 50       | 10       | 70%        | 30%      |
| 22 | 50       | 15       | 90%        | 10%      |
| 23 | 50       | 15       | 80%        | 20%      |
| 24 | 50       | 15       | 70%        | 30%      |
| 25 | 50       | 20       | 90%        | 10%      |
| 26 | 50       | 20       | 80%        | 20%      |
| 27 | 50       | 20       | 70%        | 30%      |

Untuk mengevaluasi kinerja model yang dihasilkan oleh algoritma ABC, digunakan fungsi yang menghitung RMSE, MAE, dan MAPE dari model XGBoost berdasarkan hiperparameter hasil optimasi. Fungsi ini memisahkan data menjadi data latih dan uji, melatih model, dan menghitung performa prediksi model untuk evaluasi yang komprehensif.

Didefinisikan fungsi untuk mempermudah pengujian berbagai skema hiperparameter dengan menggunakan ABC. Fungsi ini menghasilkan solusi terbaik dari setiap iterasi dan mengukur waktu yang dibutuhkan untuk konvergensi serta performa model dengan metrik evaluasi yang ditentukan. Hasil dari fungsi ini dikumpulkan dan dianalisis untuk menentukan skema terbaik berdasarkan rata-rata nilai metrik evaluasi dan waktu komputasi.

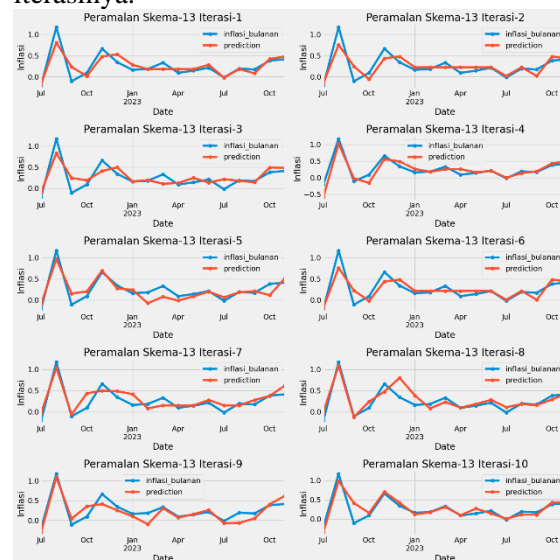
|    | population | generation | test_size | RMSE     | MAE      | MAPE     | elapsed_time |
|----|------------|------------|-----------|----------|----------|----------|--------------|
| 0  | 10         | 10         | 0.1       | 0.186478 | 0.148481 | 1.050919 | 29.986458    |
| 1  | 10         | 10         | 0.2       | 0.224018 | 0.171308 | 1.355730 | 33.630030    |
| 2  | 10         | 10         | 0.3       | 0.229053 | 0.174670 | 1.562934 | 33.207410    |
| 3  | 10         | 15         | 0.1       | 0.171545 | 0.135163 | 1.045892 | 46.250465    |
| 4  | 10         | 15         | 0.2       | 0.219472 | 0.165876 | 1.383537 | 48.600536    |
| 5  | 10         | 15         | 0.3       | 0.230751 | 0.173440 | 1.606810 | 46.406405    |
| 6  | 10         | 20         | 0.1       | 0.184259 | 0.138390 | 0.936562 | 56.585724    |
| 7  | 10         | 20         | 0.2       | 0.224765 | 0.164096 | 1.270416 | 62.331897    |
| 8  | 10         | 20         | 0.3       | 0.223249 | 0.171207 | 1.509827 | 62.019834    |
| 9  | 30         | 10         | 0.1       | 0.160385 | 0.126839 | 1.052005 | 54.805969    |
| 10 | 30         | 10         | 0.2       | 0.210092 | 0.155740 | 1.215786 | 67.485844    |
| 11 | 30         | 10         | 0.3       | 0.222875 | 0.173208 | 1.535077 | 61.190645    |
| 12 | 30         | 15         | 0.1       | 0.155066 | 0.115655 | 0.795767 | 90.328745    |
| 13 | 30         | 15         | 0.2       | 0.208922 | 0.162617 | 1.339841 | 98.383484    |
| 14 | 30         | 15         | 0.3       | 0.216349 | 0.164476 | 1.481292 | 95.764334    |
| 15 | 30         | 20         | 0.1       | 0.159197 | 0.121585 | 0.837034 | 120.800852   |
| 16 | 30         | 20         | 0.2       | 0.202293 | 0.152480 | 1.188918 | 123.167471   |
| 17 | 30         | 20         | 0.3       | 0.211071 | 0.159047 | 1.505228 | 131.207133   |
| 18 | 50         | 10         | 0.1       | 0.163611 | 0.130726 | 0.955585 | 101.221548   |
| 19 | 50         | 10         | 0.2       | 0.205973 | 0.159250 | 1.264319 | 103.647698   |
| 20 | 50         | 10         | 0.3       | 0.216386 | 0.164858 | 1.567966 | 108.258820   |
| 21 | 50         | 15         | 0.1       | 0.162731 | 0.125731 | 0.895355 | 150.332403   |
| 22 | 50         | 15         | 0.2       | 0.197583 | 0.154837 | 1.367674 | 150.848808   |
| 23 | 50         | 15         | 0.3       | 0.216226 | 0.164594 | 1.547791 | 158.177717   |
| 24 | 50         | 20         | 0.1       | 0.154527 | 0.124954 | 0.931547 | 199.218351   |
| 25 | 50         | 20         | 0.2       | 0.203744 | 0.157891 | 1.311049 | 203.594271   |
| 26 | 50         | 20         | 0.3       | 0.208158 | 0.166619 | 1.515086 | 196.297169   |

Gambar 3 Hasil Rata-rata Setiap Skema

Hasil evaluasi menunjukkan skema terbaik untuk metrik RMSE adalah skema ke-25, dengan 50 lebah, 20 generasi, dan ukuran data uji 10%. Skema ini mencatat rata-rata RMSE sebesar 0.154527, MAE 0.124954, dan MAPE 0.931547, dengan waktu komputasi sekitar 199.21 detik. Di sisi lain, skema dengan performa RMSE terburuk adalah skema ke-6, menggunakan 10 lebah, 15 generasi, dan ukuran data uji 30%, dengan rata-rata RMSE 0.230751, MAE 0.173440, dan MAPE 1.606810, serta waktu komputasi rata-rata 46.4 detik.

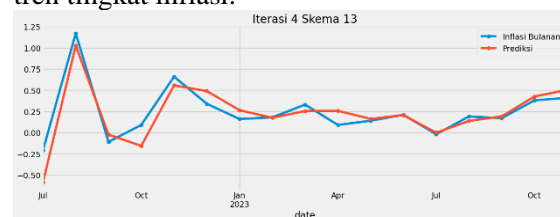
Hasil analisis menunjukkan bahwa peningkatan jumlah lebah dan generasi cenderung meningkatkan nilai RMSE, MAE, dan MAPE secara konsisten. Meskipun demikian, peningkatan ini juga diiringi oleh lonjakan signifikan dalam waktu komputasi. Ukuran data uji 10% menunjukkan performa yang lebih baik dibandingkan dengan 20% atau 30%, dengan perbedaan waktu komputasi yang minimal. Skema terbaik, yaitu dengan 30 lebah, 15 generasi, dan ukuran data uji 10%, berhasil memberikan hasil optimal dengan rata-rata skor RMSE 0.155066, MAE 0.115655, dan MAPE 0.795767, serta waktu komputasi sekitar 90.32 detik. Hasil tersebut menjadikannya pilihan yang seimbang antara akurasi dan efisiensi waktu. Berikut merupakan plotting peramalan

untuk setiap iterasi pada skema ke-13, yang memungkinkan untuk melihat perkembangan dan stabilitas hasil peramalan untuk setiap iterasinya.



Gambar 4 Hasil Peramalan Tiap Iterasi pada Skema 13

Berdasarkan gambar 6, skema ke-13 menunjukkan hasil baik di setiap iterasinya. Iterasi ini mampu mengikuti tren dengan baik dan memiliki error minimal antara nilai sebenarnya dan nilai prediksi. Iterasi terbaik adalah iterasi ke-4, dengan skor RMSE 0.138175, MAE 0.100981, dan MAPE 0.626815. Prediksi umumnya mengikuti nilai target dengan kesalahan relatif kecil, meski ada beberapa prediksi seperti pada Oktober 2022 dan April 2023, dimana model salah membaca tren tingkat inflasi.



Gambar 5 Iterasi 4 Skema 13

Secara keseluruhan, skema ke-13 menunjukkan performa yang baik dengan hasil peramalan yang stabil dan akurat di sebagian besar iterasi. Meskipun demikian, masih ada ruang untuk perbaikan, khususnya dalam memahami penyebab kesalahan dalam membaca tren pada beberapa prediksi, seperti yang terjadi pada Oktober 2022 dan April 2023.

## 5. KESIMPULAN

Berikut adalah beberapa kesimpulan yang diperoleh dari penelitian yang telah dilakukan:

- Implementasi gabungan antara Algoritma Koloni Lebah Buatan (ABC) dan XGBoost berhasil digunakan untuk memprediksi tingkat inflasi bulanan di Indonesia.
- Kombinasi antara algoritma *Artificial bee colony* dan XGBoost dievaluasi berdasarkan 27 skenario pengujian yang dijalankan 10 kali. Hasil menunjukkan bahwa secara keseluruhan, skenario dengan performa terbaik adalah skenario ke-13, menggunakan 30 lebah, 15 generasi, dan ukuran data uji 10%. Meskipun memiliki sedikit penurunan pada skor RMSE dibandingkan skenario ke-25, skema ini menunjukkan performa baik dari segi metrik lainnya dan waktu komputasi yang lebih cepat, dengan rata-rata RMSE 0.155066, MAE 0.115655, MAPE 0.795767, dan waktu komputasi rata-rata sekitar 1 menit 30 detik, dua kali lebih cepat dari skenario ke-25.

## UCAPAN TERIMA KASIH

Puji dan syukur saya panjatkan kepada Tuhan Yang Maha Esa, Dengan rasa rendah hati, saya ingin mengucapkan terima kasih yang dalam kepada semua pihak yang telah memberikan dukungan dan bimbingan selama proses penulisan karya tulis ilmiah ini. Tanpa bantuan mereka, saya tidak akan mampu menyelesaikan perjalanan ini dengan sukses. Saya menyadari bahwa karya tulis ilmiah ini belum sempurna, dan saya sangat mengharapkan kritik dan saran yang membangun untuk perbaikan di masa mendatang.

## DAFTAR PUSTAKA

- E. F. B. Simanungkalit, "PENGARUH INFLASI TERHADAP PERTUMBUHAN EKONOMI DI INDONESIA," *J. Manage.*, vol. 13, no. 3, pp. 327–340, 2020.
- A. N. Alfiyatin, W. F. Mahmudy, C. F. Ananda, and Y. P. Anggodo, "Penerapan Extreme Learning Machine (ELM) untuk Peramalan Laju Inflasi di Indonesia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 2, p. 179, 2019, doi: 10.25126/jtiik.201962900.
- T. Chen and T. He, "Extreme Gradient Boosting (XGBoost)," pp. 1–4, 2015, [Online]. Available: <https://xgboost.readthedocs.io/en/latest/>
- S. Ben Jabeur, S. Mefteh-Wali, and J. L. Viviani, "Forecasting gold price with the XGBoost algorithm and SHAP interaction values," *Ann. Oper. Res.*, no. 0123456789, 2021, doi: 10.1007/s10479-021-04187-w.
- C. Qin, Y. Zhang, F. Bao, C. Zhang, P. Liu, and P. Liu, "XGBoost optimized by adaptive particle swarm optimization for credit scoring," *Math. Probl. Eng.*, vol. 2021, 2021, doi: 10.1155/2021/6655510.
- X. Tang and L. Chen, "Artificial bee colony optimization-based weighted extreme learning machine for imbalanced data learning," *Cluster Comput.*, vol. 22, no. s3, pp. 6937–6952, 2019, doi: 10.1007/s10586-018-1808-9.
- M. Hafidz Meiditambua Saefulloh, M. Rizah Fahlevi, and S. Alfa Centauri, "Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi: Perspektif Indonesia," *J. Keuang. Negara dan Kebijakan. Publik*, vol. 3, no. 1, pp. 17–26, 2023.
- R. Christianingrum and R. A. Syafri, "Faktor-Faktor Yang Memengaruhi Inflasi Inti Di Indonesia," *J. Budg. Isu dan Masal. Keuang. Negara*, vol. 4, no. 2, pp. 18–39, 2019, doi: 10.22212/jbudget.v4i2.26.
- E. Silvia, Y. Wardi, and H. Aimon, "Analisis Pertumbuhan Ekonomi, Investasi, Dan Inflasi Di Indonesia," *J. Kaji. Ekon.*, vol. 1, no. 2, p. 7105, 2013.
- D. O. M. Abbas, "Forecasting with Machine Learning Methods," *Adv. Stud. Theor. Appl. Econom.*, vol. 53, pp. 111–149, 2017, doi: 10.1007/978-3-031-15149-1\_4.
- Y. Rismawanti and M. Y. Darsyah, "Perbandingan Peramalan Metode Moving Average dan Exponential Smoothing Holt Winter Untuk Menentukan Peramalan Inflasi di Indonesia," *Pros. Semin. Nas. Mhs. Unimus*, vol. 1, no. 1, pp. 330–335, 2018.
- A. Nasution, "Metode Weighted Moving Average Dalam M-Forecasting," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 5, no. 2, pp. 119–124, 2019, doi: 10.33330/jurteks.v5i2.355.
- J. Mateo, J. M. Rius-Peris, A. I. Marañón-Pérez, A. Valiente-Armero, and A. M. Torres, "Extreme gradient boosting machine learning method for predicting medical treatment in patients with acute bronchiolitis," *Biocybern. Biomed. Eng.*, vol. 41, no. 2, pp. 792–801, 2021, doi: 10.1016/j.bbe.2021.04.015.
- S. Rahayu Fitri, "Optimasi Jalur Distribusi Produk dengan Menggunakan Metode Saving Matrix untuk Penghematan Biaya Operasional,"

- J. Valtech*, vol. 1, no. 1, pp. 103–109, 2018.
- [15] C. Gambella, B. Ghaddar, and J. Naoum-Sawaya, “Optimization problems for machine learning: A survey,” *Eur. J. Oper. Res.*, vol. 290, no. 3, pp. 807–828, 2021, doi: 10.1016/j.ejor.2020.08.045.
  - [16] S. Sun, Z. Cao, H. Zhu, and J. Zhao, “A Survey of Optimization Methods from a Machine Learning Perspective,” *IEEE Trans. Cybern.*, vol. 50, no. 8, pp. 3668–3681, 2020, doi: 10.1109/TCYB.2019.2950779.
  - [17] D. Karaboga and B. Akay, “A comparative study of *Artificial bee colony* algorithm,” *Appl. Math. Comput.*, vol. 214, no. 1, pp. 108–132, 2009, doi: 10.1016/j.amc.2009.03.090.
  - [18] A. S. B. Karno, “Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory),” *J. Inform. Inf. Secur.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.31599/jiforty.v1i1.133.
  - [19] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
  - [20] A. de Myttenaere, B. Golden, B. Le Grand, and F. Rossi, “Mean Absolute Percentage Error for regression models,” *Neurocomputing*, vol. 192, pp. 38–48, 2016, doi: 10.1016/j.neucom.2015.12.114.
  - [21] A. A. Suryanto, “Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi,” *Saintekbu*, vol. 11, no. 1, pp. 78–83, 2019, doi: 10.32764/saintekbu.v11i1.298.
  - [22] R. Luo, L. Guo, X. Li, J. Tuo, C. Lei, and Y. Zhou, “An eXtreme Gradient Boosting Algorithm Combining *Artificial bee colony* Parameters Optimized Technique for Single Sand Body Identification,” *IEEE Access*, vol. 9, pp. 156894–156906, 2021, doi: 10.1109/ACCESS.2021.3129830.
  - [23] D. Karaboga and B. Gorkemli, “A quick *artificial bee colony* (qABC) algorithm and its performance on optimization problems,” *Appl. Soft Comput. J.*, vol. 23, pp. 227–238, 2014, doi: 10.1016/j.asoc.2014.06.035.