

e-ISSN: 2502-1516

Research Articles

Dikirim: 9 Juli 2025  
Direvisi: 6 Juli 2026  
Diterima: 28 Juli 2026  
Tersedia Online: September 2026

**PERAMALAN PRODUKSI HERBISIDA PADA INDUSTRI AGROKIMIA MENGGUNAKAN LSTM BERBASIS *BAYESIAN OPTIMIZATION***

**Kata Kunci:**  
agrokimia; *Bayesian Optimization*; BO-LSTM; herbisida; LSTM; peramalan deret waktu

**Louis Putra Purnama<sup>1\*</sup>, Dedy Sugiarto<sup>2</sup>, Heri Santosa<sup>1</sup>**

**Penulis korespondensi:**  
e-mail:  
163012300005@std.trisakti.ac.id

1. Magister Teknik Industri, Fakultas Teknologi Industri, Universitas Trisakti, Jl. Kyai Tapa No. 1 Grogol, Jakarta Barat, Indonesia, 11440  
2. Program Studi Sistem Informasi, Fakultas Teknologi Industri, Universitas Trisakti, Jl. Kyai Tapa No. 1 Grogol, Jakarta Barat, Indonesia, 11440

**Abstrak**

Peramalan produksi herbisida di industri agrokimia menghadapi tantangan besar akibat fluktuasi permintaan musiman dan dampak perubahan iklim. Metode konvensional sering kali gagal menangkap pola non-linier yang kompleks, menghasilkan akurasi prediksi yang rendah. Untuk mengatasi keterbatasan ini, penelitian ini mengembangkan model Long Short-Term Memory (LSTM) yang dioptimalkan menggunakan Bayesian Optimization (BO) untuk peramalan produksi herbisida bulanan. Penelitian ini membandingkan kinerja model LSTM konvensional dengan model BO-LSTM. Data historis produksi dari Januari 2019 hingga Desember 2023 digunakan, setelah melalui praproses data dan normalisasi dengan Min-Max Scaler. Hasil terbaik model LSTM konvensional menunjukkan MAPE 11,33%, tetapi pendekatan konvensional memerlukan banyak percobaan manual dan tidak efisien. Sebaliknya, pendekatan BO memungkinkan pengoptimalan hyperparameter LSTM yang terintegrasi, menghasilkan model BO-LSTM dengan performa yang lebih baik dengan MAE 37.588,61, RMSE 52.407,12, dan MAPE 7,81%. Peningkatan akurasi ini signifikan dibandingkan LSTM konvensional. Ketika model digunakan untuk peramalan tiga bulan ke depan, model menunjukkan pola yang konsisten dengan tren musiman historis. Hasil penelitian ini menegaskan bahwa integrasi BO-LSTM secara efektif meningkatkan akurasi peramalan, memberikan dasar yang lebih tepat untuk perencanaan produksi dan manajemen stok di industri agrokimia.

Copyright © 2026 by Authors,  
Published by Universitas Diponegoro Publishing Group.  
This open access article is distributed under a Creative Commons  
Attribution 4.0 International license



**1. Pendahuluan**

Proses produksi dalam industri agrokimia memiliki keterkaitan dengan perubahan musim. Contoh kasus produk agrokimia yang berkaitan dengan musim adalah herbisida. Hal ini disebabkan oleh meningkatnya permintaan herbisida menjelang musim tanam dan selama musim hujan. Pada musim tanam, gulma bertumbuh dengan cepat yang disebabkan oleh cahaya matahari dapat langsung mengenai tanah (Ratna et al., 2022). Selain itu, peningkatan kebutuhan herbisida terjadi pada musim hujan. Musim hujan berkontribusi pada meningkatnya kelembapan yang mempercepat perkecambahan gulma (Keerthi et al., 2023). Sebaliknya, permintaan herbisida menurun pada musim panas saat cahaya matahari mengurangi kelembapan tanah yang menyebabkan terhambatnya pertumbuhan gulma. Siklus musiman ini berdampak pada kapasitas produksi dan rantai pasok. Jika pola musiman ini tidak disertai peramalan produksi yang akurat, perusahaan berisiko mengalami kekurangan stok saat permintaan meningkat atau kelebihan stok pada saat permintaan menurun.

Selain faktor musiman, perubahan iklim menjadi tantangan besar dalam industri agrikultur termasuk industri pendukung seperti agrokimia (Gu et al., 2022; Habib-ur-Rahman et al., 2022; Din et al., 2021; Wasaya et al., 2022). Perubahan iklim mengakibatkan pola cuaca menjadi tidak stabil (Hidayat & Wibisonya, 2024), perubahan yang tidak menentu mempersulit pengendalian gulma yang berdampak terhadap ketidakpastian dalam permintaan herbisida

(Kumar et al., 2023). Di sisi lain, potensi pasar herbisida global diperkirakan bernilai USD 36,88 miliar pada tahun 2021 dan diproyeksikan mencapai USD 59,82 miliar pada tahun 2029 dengan CAGR 6,23% (Sălceanu et al., 2022). Tantangan dan potensi pertumbuhan tersebut menunjukkan urgensi dalam ketepatan peramalan produksi untuk menjaga ketersediaan produk, efisiensi persediaan, dan respons perusahaan terhadap fluktuasi permintaan.

Kondisi ini menghasilkan faktor-faktor yang mempengaruhi produksi menjadi lebih kompleks dan tidak dapat diprediksi dengan mudah menggunakan metode konvensional. Metode konvensional seperti regresi linier sering kali gagal menangkap pola musiman yang tidak menentu serta hubungan tidak linier yang kompleks antara variabel-variabel yang mempengaruhi produksi (Paramasivan, 2021). Karena regresi linier bekerja dengan mengasumsikan hubungan linier antara faktor-faktor yang mempengaruhi produksi, sedangkan pada kenyataannya, hubungan tersebut bersifat tidak linier dan bergantung pada berbagai faktor eksternal seperti perubahan cuaca, pola curah hujan, serta siklus pertanian. Oleh karena itu, metode konvensional ini sering menghasilkan simpangan prediksi yang besar, sehingga kurang efektif apabila digunakan untuk pengambilan keputusan dalam industri agrokimia.

Untuk mengatasi keterbatasan metode konvensional, pendekatan berbasis pembelajaran mendalam (*deep learning*) mulai banyak digunakan dalam penelitian yang berkaitan dengan peramalan deret waktu (*time-series forecasting*) (Torres et al., 2021). Algoritma pembelajaran mendalam memiliki kemampuan untuk menangkap pola musiman yang tidak linier dalam deret waktu dan mampu mengolah data dengan variasi tinggi, sehingga dapat menghasilkan akurasi prediksi yang lebih tinggi dibandingkan metode konvensional (Paramasivan, 2021). Pendekatan ini telah diterapkan di berbagai bidang, termasuk pada bidang agrikultur yang memiliki pola data musiman seperti industri agrokimia (Hidayat & Wibisonya, 2024; Ma et al., 2023; Sabu & Kumar, 2020).

Salah satu model pembelajaran mendalam yang paling efektif yang digunakan dalam peramalan data deret waktu adalah *Long Short-Term Memory* (LSTM). Model ini dirancang untuk menangani ketergantungan jangka panjang dalam data deret waktu (*time-series*) serta mampu mengenali pola kompleks dalam dinamika temporal (Gautam, 2022). Namun, meskipun LSTM memiliki keunggulan dalam mempelajari pola deret waktu, kinerjanya sangat bergantung pada pemilihan *hyperparameter* yang optimal, seperti jumlah unit LSTM, *learning rate*, *batch size*, dan *dropout rate*. Pemilihan *hyperparameter* yang tidak optimal dapat menyebabkan *overfitting* atau *underfitting*, yang berdampak pada akurasi model (Snoek et al., 2012).


Guna meningkatkan efektivitas LSTM dalam peramalan produksi herbisida, penelitian ini dilakukan dengan mengintegrasikan *Bayesian Optimization* (BO) sebagai teknik optimasi *hyperparameter* (Habtemariam et al., 2023). BO merupakan metode berbasis probabilistik yang mencari kombinasi *hyperparameter* terbaik secara lebih efisien dibandingkan metode lain seperti *grid search* atau *random search* (Alam et al., 2021; Wang et al., 2020; Wu et al., 2019). BO bekerja dengan membangun model probabilistik dari fungsi objektif yang akan dioptimalkan, lalu menggunakan informasi dari iterasi sebelumnya untuk menentukan kombinasi *hyperparameter* terbaik dengan jumlah percobaan yang lebih sedikit (Wang et al., 2020). Dengan demikian, BO berguna dalam meningkatkan akurasi prediksi LSTM dan mampu mengurangi waktu proses pelatihan model.

Penelitian sebelumnya telah membuktikan bahwa kombinasi LSTM dan *Bayesian Optimization* dapat meningkatkan akurasi dalam berbagai tugas peramalan, seperti pada pembangkit listrik tenaga angin (Habtemariam et al., 2023), konsumsi listrik (Almuhaini & Sultana, 2023), prediksi kesehatan baterai (Meng et al., 2023), dan manajemen penyimpanan (Rahmatillah et al., 2024). Namun, penerapan kombinasi BO-LSTM pada industri agrokimia, khususnya untuk peramalan produksi herbisida, masih sangat terbatas. Penelitian terdahulu dalam konteks peramalan produk agrokimia umumnya masih menggunakan metode statistik dan deret waktu konvensional, seperti *moving average* 3 dan 6 periode, *time series decomposition*, *Holt-Winters* (Ruksaphon, 2024), *single moving average* (SMA) (Dorthy Ellyany Sinaga et al., 2022), serta *Autoregressive Integrated Moving Average* (ARIMA) (Gharde, 2015).

Berdasarkan latar belakang yang telah dijelaskan, penelitian ini bertujuan untuk mengembangkan model peramalan berbasis pembelajaran mendalam menggunakan LSTM yang dioptimalkan dengan BO (BO-LSTM). Hasil penelitian akan dibandingkan dengan model LSTM konvensional, untuk mengevaluasi sejauh mana metode BO-LSTM dapat meningkatkan akurasi dalam peramalan produksi herbisida.


## 2. Metode Penelitian

Penelitian ini menggunakan metode LSTM yang dioptimalkan dengan *Bayesian Optimization* (BO) untuk meramalkan produksi bulanan herbisida yang memiliki pola produksi musiman. Setelah model peramalan dikembangkan dan diuji, akan digunakan untuk meramalkan produksi tiga bulan ke depan. Proses penelitian dilakukan secara sistematis, dimulai dari pengumpulan data, praproses data, pengembangan model LSTM, optimasi *hyperparameter*, pelatihan model, evaluasi performa, perbandingan model LSTM dengan BO-LSTM, hingga implementasi model dalam peramalan produksi tiga bulan ke depan. **Gambar 1** menampilkan diagram alir penelitian yang mencerminkan tahapan-tahapan yang dilakukan.



Gambar 1. Diagram Alir Penelitian

Grafik Produksi Herbisida 2019-2023



Gambar 2. Grafik Produksi Herbisida

## 2.1 Deskripsi Data

Dataset yang digunakan merupakan data historis produksi herbisida setiap bulan dalam rentang waktu Januari 2019 hingga Desember 2023, dengan total 60 data. Penelitian menggunakan data produksi karena proses produksi dilakukan berdasarkan pesanan pelanggan. Fluktuasi produksi yang terjadi dalam data dipandang sebagai representasi tidak langsung dari perubahan kebutuhan produksi yang dapat dipengaruhi oleh faktor musiman dan kondisi eksternal. Oleh karena itu, model yang dikembangkan bersifat univariat, yaitu hanya menggunakan data historis produksi herbisida dari waktu ke waktu.

Data ini berisi informasi mengenai bulan dan jumlah produksi herbisida setiap bulan dalam satuan liter. Sumber data berasal dari data primer internal perusahaan agrokimia yang berlokasi di Jawa Barat, Indonesia. Data dikumpulkan melalui sistem pencatatan produksi perusahaan. **Gambar 2** menampilkan grafik produksi herbisida dari waktu ke

waktu. Meskipun jumlah 60 data relatif terbatas untuk pengembangan model *deep learning* berskala besar, data ini masih dapat digunakan untuk peramalan deret waktu univariat karena memuat lima siklus tahunan produksi. Dengan demikian, model dapat mempelajari kecenderungan pola historis, fluktuasi naik-turun produksi, serta indikasi pola musiman yang muncul dalam data. Pada penelitian lain, data deret waktu berjumlah 60 data menunjukkan bahwa LSTM dapat digunakan pada *dataset* terbatas apabila model dikembangkan dengan ruang lingkup yang jelas (Taslim & Murwantara, 2024). Untuk memahami pola dalam data sebelum melakukan pemodelan, dilakukan visualisasi tren produksi herbisida. *Seasonal decomposition* digunakan untuk mengidentifikasi fluktuasi musiman, tren peningkatan atau penurunan produksi, serta pola lainnya yang dapat berpengaruh terhadap hasil. **Gambar 3** menampilkan grafik pola data hasil pengolahan *seasonal decomposition*.

## 2.2 Praproses Data


Tahap praproses data dilakukan untuk memastikan kualitas data sebelum digunakan dalam model LSTM. Praproses data terdiri dari tiga tahap utama. Tahap pertama adalah pembersihan *dataset*, tahap ini bertujuan untuk menghapus data yang tidak konsisten, nilai yang hilang (*missing values*), atau data yang tidak lengkap (Nugraha et al., 2024). Pada penelitian ini, *dataset* yang diperoleh berjumlah 60 data, dan setelah proses validasi tidak ditemukan nilai 0. Oleh karena itu, karena tidak ditemukan nilai yang perlu ditangani dalam proses validasi, tidak dilakukan imputasi maupun penghapusan data. Setelah pembersihan data dilanjutkan dengan pembagian data dengan perbandingan 54 data digunakan sebagai data pelatihan model dan 6 data digunakan untuk mengukur performa model dalam melakukan prediksi. Tahap terakhir dalam praproses adalah melakukan normalisasi data pelatihan. Tahap ini dilakukan untuk memastikan model LSTM dapat belajar secara optimal. Pada tahap ini dilakukan pemeriksaan skala data. Pada *dataset* yang digunakan terdapat tingkat variasi jumlah produksi yang dapat berubah, sehingga perlu dilakukan transformasi data. Transformasi data dilakukan menggunakan *Min-Max Scaler* (Priyambudi & Nugroho, 2024). Penggunaan *Min-Max Scaler* dilakukan agar menyederhanakan rentang nilai antara 0 dan 1. Persamaan metode dan *Min-Max Scaler* ditunjukkan dalam **Persamaan 1**.

$$Y_t = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (\text{Persamaan 1})$$


$Y_t$  adalah nilai hasil normalisasi pada waktu ke- $t$ .  $X$  adalah nilai aktual.  $X_{\min}$  adalah nilai minimum dari data  $X$ , dan  $X_{\max}$  adalah nilai maksimum dari data  $X$ .

## 2.3 Membangun Model LSTM

Model *Long Short-Term Memory* (LSTM) merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi keterbatasan dalam menyimpan informasi jangka panjang akibat masalah *vanishing gradient* (Hochreiter & Schmidhuber, 1997). LSTM merupakan solusi atas kelemahan RNN konvensional yang mengalami kesulitan dalam menangani korelasi temporal jangka panjang karena gradien fungsi kehilangan yang



**Gambar 3.** Grafik Pola Data Produksi Herbisida



Gambar 4. Arsitektur LSTM

menyusut secara eksponensial seiring waktu. LSTM mengatasi hal ini dengan memperkenalkan unit sel (*cell unit*) dan tiga gerbang utama pada lapisan tersembunyinya, yaitu gerbang masuk yang mengatur informasi baru yang masuk, gerbang lupa yang menentukan informasi mana yang perlu dihapus, dan gerbang keluar yang mengatur informasi yang diteruskan seperti ditunjukkan pada **Gambar 4** yang menggambarkan arsitektur LSTM.

Tahap pertama dari LSTM adalah gerbang lupa (*Forget Gate*) yang bertugas menentukan informasi mana yang perlu dihapus dari sel keadaan (*Cell State*). Gerbang lupa menerima dua *input*, yaitu  $h_{t-1}$  sebagai *output* dari proses LSTM pada waktu sebelumnya, serta  $x_t$  yang merupakan *input* saat ini. Persamaan gerbang lupa ditunjukkan dalam **Persamaan 2**.

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (\text{Persamaan 2})$$

$f_t$  adalah gerbang lupa,  $\sigma$  adalah fungsi aktivasi sigmoid,  $W_f$  adalah bobot gerbang lupa,  $h_{t-1}$  adalah nilai *output* pada waktu sebelumnya,  $x_t$  adalah nilai *input* saat ini, dan  $b_f$  adalah bias dari gerbang lupa.

Tahap berikutnya, gerbang masuk (*input gate*) berfungsi untuk memilih informasi baru yang akan disimpan dalam sel keadaan. Gerbang masuk memiliki dua komponen utama, yaitu lapisan *sigmoid* yang menentukan informasi yang akan diperbarui, serta lapisan *tanh* yang menghasilkan vektor baru untuk ditambahkan ke sel keadaan. Kedua persamaan gerbang masuk ditunjukkan pada **Persamaan 3** dan **Persamaan 4**.

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (\text{Persamaan 3})$$

$$\tilde{C}_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (\text{Persamaan 4})$$

$i_t$  adalah gerbang masuk,  $\sigma$  adalah fungsi aktivasi *sigmoid*,  $W_i$  adalah bobot gerbang *input*,  $h_{t-1}$  adalah *output* pada waktu sebelumnya,  $x_t$  adalah *input* saat ini,  $b_i$  adalah bias gerbang masuk,  $\tilde{C}_t$  adalah nilai baru yang akan dimasukkan ke dalam sel keadaan,  $\tanh$  adalah fungsi aktivasi *tanh*,  $W_c$  adalah bobot untuk sel keadaan, dan  $b_c$  adalah bias dari sel keadaan.

Selanjutnya, sel keadaan diperbarui dengan mengalikan nilai gerbang lupa dengan sel keadaan sebelumnya ( $C_{t-1}$ ), lalu menambah hasil perkalian dari gerbang masuk ( $i_t$ ) dan nilai baru yang dihasilkan oleh lapisan *tanh* ( $\tilde{C}_t$ ). Persamaan ini ditunjukkan pada **Persamaan 5**.

$$C_t = (f_t \odot C_{t-1} + i_t \odot \tilde{C}_t) \quad (\text{Persamaan 5})$$

$C_t$  adalah sel keadaan terbaru,  $f_t$  adalah gerbang lupa,  $C_{t-1}$  adalah sel keadaan sebelumnya,  $i_t$  adalah gerbang masuk, dan  $\tilde{C}_t$  adalah nilai baru yang akan ditambahkan ke sel keadaan.

Tahap terakhir adalah gerbang keluar (*output gate*), Tahap ini menentukan nilai dari sel keadaan yang akan menjadi *output* saat ini. Proses ini dilakukan dengan mengaktifkan nilai menggunakan fungsi *sigmoid*, dan kemudian mengalikan hasilnya dengan aktivasi *tanh* dari sel keadaan. Persamaan untuk gerbang keluar ditunjukkan pada **Persamaan 6** dan **Persamaan 7**.

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (\text{Persamaan 6})$$

$$h_t = o_t \odot \tanh(C_t) \quad (\text{Persamaan 7})$$

$o_t$  adalah gerbang keluar,  $\sigma$  merupakan fungsi aktivasi *sigmoid*,  $W_o$  adalah bobot gerbang keluar,  $h_{t-1}$  adalah *output* pada waktu sebelumnya,  $x_t$  adalah *input* saat ini,  $b_o$  adalah bias gerbang keluar,  $h_t$  adalah *output* terbaru,  $\tanh$  adalah fungsi aktivasi *tanh*, dan  $C_t$  adalah sel keadaan.

Fungsi aktivasi dalam pembelajaran mendalam berperan dalam menangani data dalam jumlah besar dengan kompleksitas tinggi. Fungsi ini menentukan apakah suatu neuron akan diaktifkan atau tidak. LSTM menggunakan dua jenis fungsi aktivasi, yaitu *sigmoid* ( $\sigma$ ) dan *tanh*. Fungsi aktivasi *sigmoid* memiliki hasil rentang nilai 0 dan 1. Sementara itu, fungsi aktivasi *tanh*, juga dikenal sebagai hiperbolik tangen, memiliki rentang nilai antara -1 hingga 1. Persamaan untuk dua fungsi aktivasi ini ditunjukkan pada **Persamaan 8** dan **Persamaan 9**.

$$f(x) = \frac{1}{(1+e^{-x})} \quad (\text{Persamaan 8})$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (\text{Persamaan 9})$$

## 2.4 Bayesian Optimization

Model prediktif berbasis *pembelajaran mendalam*, dapat ditingkatkan melalui optimasi *hyperparameter*. BO membuat model probabilistik berdasarkan fungsi objektif untuk menentukan *hyperparameter* optimal secara terinformasi, sehingga mengurangi jumlah eksekusi fungsi objektif dengan memilih kumpulan *hyperparameter* yang paling menjanjikan. Pendekatan BO terdiri dari dua sub-model yaitu model pengganti (probabilistik) dan akuisisi. Model pengganti (probabilistik) merupakan komponen yang digunakan memperkirakan fungsi objektif secara efisien. Model pengganti yang umumnya digunakan adalah Proses Gaussian (GP). GP membangun pendekatan probabilistik terhadap fungsi objektif dan membantu memilih kombinasi *hyperparameter* yang paling menjanjikan untuk dievaluasi (Abdalla et al., 2021; Alam et al., 2021). Persamaan untuk proses gaussian dijelaskan pada **Persamaan 10**.

$$f(z) \sim GP(m(z), k(z_i, z_j)) \quad (\text{Persamaan 10})$$

Fungsi  $f(z)$  adalah representasi dari proses Gaussian,  $m(z)$  adalah fungsi rata-rata (*mean function*), dan  $k(z_i, z_j)$  adalah fungsi kovarian. Nilai  $z$  adalah nilai fungsional dengan seluruh kombinasi dari  $(z_i, z_j)$  dalam domain *input*. Fungsi kovarian, juga disebut kernel, berperan penting dalam menggambarkan hubungan antara variabel dalam domain *input*. Kernel bertugas menentukan kedekatan antar titik memengaruhi nilai fungsi, serta mengontrol **kelancaran** (*smoothness*) dan **amplitudo** dari sampel yang dihasilkan oleh proses Gaussian.

Fungsi akuisisi digunakan dalam menentukan titik-titik dalam ruang pencarian yang membutuhkan evaluasi dan memberikan informasi mengenai kemungkinan lokasi nilai optimal dari fungsi yang sedang dioptimalkan. Tujuan fungsi akuisisi adalah menggunakan informasi *posterior* untuk menemukan titik sampel terbaik pada setiap iterasi, kemudian mengusulkan titik sampel baru guna mengidentifikasi kumpulan *hyperparameter* paling menjanjikan untuk dievaluasi. Optimasi *hyperparameter* dijelaskan dalam **Persamaan 11**.

$$g^* = \arg \min_{g \in G} f(g) \quad (\text{Persamaan 11})$$

$f(g)$  adalah fungsi objektif untuk meminimalkan kesalahan validasi,  $g^*$  adalah kumpulan *hyperparameter* optimal yang menghasilkan nilai minimum dari fungsi objektif, dan  $g$  adalah kombinasi *hyperparameter* yang diambil dari ruang  $G$ .

## 2.5 Evaluasi Performa

Evaluasi model pada data uji dilakukan menggunakan pendekatan *rolling forecast*. Pendekatan ini digunakan karena data yang dianalisis merupakan data deret waktu, sehingga proses pengujian perlu mempertahankan urutan kronologis data. Dalam penelitian ini, model dilatih menggunakan data historis produksi, kemudian digunakan untuk memprediksi data uji secara bertahap. Prediksi dilakukan dengan memanfaatkan urutan *input* sebelumnya, kemudian hasil prediksi digunakan sebagai bagian dari proses pembentukan input untuk periode berikutnya. Dengan demikian, evaluasi model tidak dilakukan secara acak, tetapi mengikuti pola peramalan nyata, yaitu memprediksi periode selanjutnya berdasarkan informasi historis yang tersedia. Pendekatan *rolling forecast* ini digunakan untuk menilai kemampuan model dalam melakukan prediksi bertahap pada data yang belum digunakan dalam proses pelatihan.

Evaluasi kinerja dilakukan untuk membandingkan seberapa akurat model LSTM konvensional dan model BO-LSTM dalam memprediksi data produksi. Terdapat tiga metrik statistik berbeda yang digunakan dalam mengevaluasi kinerja model yaitu, *mean absolute error* (MAE), *root mean square error* (RMSE), dan *mean absolute percentage error* (MAPE). Ketiga metrik ini digunakan untuk memberikan gambaran yang komprehensif tentang performa model dalam berbagai aspek. MAE digunakan untuk mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual. RMSE digunakan untuk mengukur perbedaan antara nilai aktual dan nilai prediksi. Sedangkan MAPE digunakan untuk membandingkan performa model pada *dataset* yang memiliki skala nilai berbeda. MAPE berguna karena memberikan hasil dalam bentuk persentase deviasi prediksi dari nilai sebenarnya. Ketiga metrik statistik didefinisikan dalam **Persamaan 12**, **Persamaan 13**, dan **Persamaan 14**.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (\text{Persamaan 12})$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (\text{Persamaan 13})$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y - \hat{y}}{y} \right| \times 100 \quad (\text{Persamaan 14})$$

$y$  adalah nilai aktual.  $\hat{y}$  adalah nilai prediksi. Sedangkan  $n$  adalah jumlah total data pengujian yang digunakan untuk mengevaluasi model.


### 3. Hasil dan Pembahasan

Pelatihan model dilakukan menggunakan *Google Colaboratory* dengan bahasa *Python* dan kerangka kerja *TensorFlow/Keras*. Model LSTM dibangun dengan satu lapisan LSTM dengan jumlah unit LSTM sebanyak 100 neuron dengan fungsi aktivasi ReLU, dan *output dense* menggunakan satu lapisan. Optimasi model dilakukan menggunakan algoritma Adam karena efisien dalam menangani permasalahan optimasi *non-konveks*. Sedangkan pada fungsi kehilangan (*loss function*) menggunakan *Mean Squared Error* (MSE) untuk mengukur selisih kuadrat antara nilai aktual dan prediksi. Model dilatih selama 50 dan 75 *epoch* dengan *batch size* sebesar 1, panjang urutan *input* ( $n_{input}$ ) yang digunakan adalah 6 dan 12. Konfigurasi ini digunakan untuk membaca pola musiman per musim dan membaca pola musiman selama satu tahun. Pemilihan beberapa panjang urutan *input* penting dilakukan untuk menemukan nilai yang optimal (Britania, 2022). Untuk memastikan model dapat dilakukan pengulangan, nilai *random seed* ditetapkan sebesar 42. Detail parameter yang digunakan untuk model LSTM konvensional ditampilkan pada **Tabel 1**.


Setelah dilakukan evaluasi performa terhadap model pertama yang menggunakan panjang urutan *input* sebesar 6 dan dilatih selama 50 *epoch*, diperoleh nilai MAE sebesar 118.136,35, RMSE sebesar 158.173,65, dan MAPE sebesar 24,46%. Selanjutnya, model kedua dengan panjang urutan *input* yang sama, namun dilatih selama 75 *epoch*, menghasilkan nilai MAE sebesar 131.255,53, RMSE sebesar 183.121,94, dan MAPE sebesar 24,13%. Berdasarkan hasil tersebut, model kedua memang memiliki nilai MAPE yang sedikit lebih rendah, dengan selisih sebesar 0,33%. Namun demikian, model pertama menunjukkan performa yang lebih baik secara keseluruhan karena memiliki nilai MAE dan RMSE yang lebih rendah, yang mengindikasikan kesalahan absolut dan kesalahan kuadrat rata-rata yang lebih kecil. Jika diamati melalui visualisasi pada **Gambar 5**, pola prediksi dari kedua model belum sepenuhnya mencerminkan pola musiman yang sebenarnya terjadi. Hal ini mengindikasikan bahwa kombinasi parameter yang digunakan pada kedua model masih belum optimal untuk menangkap karakteristik musiman dalam peramalan produksi herbisida.

**Tabel 1.** Hyperparameter Model LSTM

| No | Jenis                          | Nilai/Uraian                      |
|----|--------------------------------|-----------------------------------|
| 1  | Jumlah Layer                   | 2 (1 LSTM + 1 Dense)              |
| 2  | Jumlah Unit LSTM               | 100                               |
| 3  | Fungsi Aktivasi                | ReLU                              |
| 4  | Optimizer                      | Adam                              |
| 5  | Fungsi Loss                    | MSE ( <i>Mean Squared Error</i> ) |
| 6  | Epoch                          | 50 dan 75                         |
| 7  | Batch Size                     | 1                                 |
| 8  | Input Sequence ( $n_{input}$ ) | 6 dan 12                          |
| 9  | Feature                        | 1 (Univariat: produksi)           |
| 10 | Random Seed                    | 42 (Produksi ulang)               |



**Gambar 5.** Grafik Hasil Prediksi Model 1 dan 2



**Gambar 6.** Grafik Hasil Prediksi Model 3 dan 4

**Tabel 2.** Perbandingan Data Uji dan Prediksi Model BO-LSTM

| Bulan | Tanggal        | Produksi | Prediksi BO-LSTM | Error MAPE |
|-------|----------------|----------|------------------|------------|
| 55    | Juli 2023      | 448.708  | 444.665,3        | 0,9        |
| 56    | Agustus 2023   | 412.512  | 332.712,8        | 19,3       |
| 57    | September 2023 | 299.914  | 321.196,3        | 7,1        |
| 58    | Oktober 2023   | 368.213  | 379.655,7        | 3,1        |
| 59    | November 2023  | 523.068  | 510.860,1        | 2,3        |
| 60    | Desember 2023  | 686.476  | 589.719,2        | 14,1       |

Selanjutnya, dilakukan evaluasi terhadap model ketiga yang menggunakan panjang urutan *input* sebesar 12, dengan tujuan untuk menangkap pola musiman selama satu tahun. Model ini dilatih selama 50 *epoch* dan menghasilkan nilai MAE sebesar 55.648,39, RMSE sebesar 75.576,08, dan MAPE sebesar 11,33%. Hasil ini menunjukkan perbaikan yang signifikan dibandingkan dua model sebelumnya, baik dari segi akurasi prediksi maupun kemampuan model dalam mengenali pola musiman yang dapat dilihat pada **Gambar 6**. Model keempat, yang memiliki konfigurasi *input* yang sama namun dilatih selama 75 *epoch*, justru menunjukkan penurunan performa dengan nilai MAE sebesar 63.719,99, RMSE sebesar 83.818,99, dan MAPE sebesar 12,68%. Perbandingan ini menunjukkan bahwa penambahan jumlah *epoch* tidak selalu meningkatkan kinerja model.

Jika dibandingkan dengan model pertama dan kedua, model ketiga tidak hanya mencatat nilai MAPE yang paling rendah, tetapi juga menunjukkan keseimbangan antara MAE dan RMSE yang lebih baik. Hal ini mengindikasikan bahwa pemilihan panjang urutan *input* sebesar 12 memberikan kontribusi yang signifikan terhadap peningkatan akurasi model, terutama dalam menangkap pola jangka panjang yang bersifat musiman. Meski begitu, nilai MAPE yang dihasilkan model ketiga masih berada sedikit di atas ambang batas 10% yang merupakan batas atas prediksi yang akurat dalam konteks peramalan.


Berdasarkan hasil evaluasi terhadap 4 model LSTM konvensional, dilakukan pengembangan model BO-LSTM. Optimasi dengan pendekatan *Bayesian Optimization* digunakan untuk menemukan kombinasi *hyperparameter* terbaik secara efisien yang diharapkan dapat meningkatkan akurasi. Dalam penelitian ini tiga *hyperparameter* utama yang dioptimasi meliputi panjang urutan *input* (*n\_input*), jumlah unit LSTM (*lstm\_units*), dan jumlah *epoch* pelatihan, masing-masing dalam rentang nilai 6–15, 50–150, dan 50–150. Untuk setiap kombinasi, model dibangun dan dilatih menggunakan *Timeseries Generator*, lalu dilakukan prediksi terhadap data uji secara bertahap melalui *rolling forecast*. Hasil prediksi dibandingkan dengan data aktual untuk menghitung nilai *Mean Absolute Percentage Error* (MAPE), yang kemudian digunakan sebagai fungsi objektif (dalam bentuk negatif) agar proses optimasi dapat diformulasikan sebagai proses maksimisasi. Untuk memastikan hasil yang konsisten dan replikatif, nilai *random seed* ditetapkan sebesar 42. Proses *Bayesian Optimization* dijalankan dengan 10 titik awal eksplorasi (*init\_points*) dan 15 iterasi pencarian (*n\_iter*).

Setelah dilakukan proses optimasi menggunakan *Bayesian Optimization*, diperoleh hasil kombinasi *hyperparameter* terbaik, yaitu panjang urutan *input* sebesar 11, jumlah unit LSTM sebanyak 79, dan jumlah *epoch* pelatihan sebanyak 93. Model akhir yang dibangun dengan konfigurasi ini menunjukkan performa evaluasi yang lebih optimal dibandingkan model LSTM konvensional. Model ini menghasilkan MAE sebesar 37.588,61, RMSE sebesar 52.407,12, dan MAPE sebesar 7,81%. **Tabel 2** menunjukkan perbandingan antara data aktual dan prediksi hasil BO-LSTM.

Berdasarkan **Tabel 2**, terlihat bahwa model BO-LSTM mampu menghasilkan prediksi yang cukup akurat pada sebagian besar bulan, dengan nilai *error* MAPE yang berada di bawah 10% pada 4 dari 6 bulan yang diuji. Misalnya, pada bulan Juli, September, Oktober, dan November 2023, *error* prediksi masing-masing tercatat sebesar 0,9%, 7,1%, 3,1%, dan 2,3%, menunjukkan kemampuan model dalam menangkap pola musiman secara konsisten. Namun, model masih mengalami kesulitan dalam memprediksi bulan Agustus dan Desember, dengan *error* MAPE masing-masing mencapai 19,3% dan 14,1%. Hal ini kemungkinan disebabkan oleh pola data yang tidak tercermin dalam pola historis, sehingga model cenderung meleset dalam memperkirakan nilai aktual.

Tabel 3. Perbandingan Evaluasi Model

| Model Latih   | MAE        | RMSE       | MAPE (%) |
|---------------|------------|------------|----------|
| Model 1       | 118.136,35 | 158.173,65 | 24,46    |
| Model 2       | 131.255,53 | 183.121,94 | 24,13    |
| Model 3       | 55.648,39  | 75.576,08  | 11,33    |
| Model 4       | 63.719,99  | 83.818,99  | 12,68    |
| Model BO-LSTM | 37.588,61  | 52.407,12  | 7,81     |



Gambar 7. Grafik Peramalan Tiga Bulan ke Depan

Meski demikian, performa keseluruhan model BO-LSTM menunjukkan hasil yang baik. Nilai MAPE sebesar 7,81% menandakan bahwa model berhasil menurunkan kesalahan prediksi dibandingkan dengan model LSTM konvensional. Setelah dilakukan empat percobaan, model LSTM konvensional menghasilkan hasil terbaik pada MAPE sebesar 11,33%. Sebaliknya, BO-LSTM berhasil menurunkan MAPE hingga di bawah 10%, terdapat penurunan *error* lebih dari 3% dibandingkan model dari LSTM konvensional. Ini memperkuat bukti bahwa pendekatan *Bayesian Optimization* tidak hanya efektif dalam mencari kombinasi *hyperparameter* terbaik, tetapi mampu meningkatkan kinerja model. Perbandingan performa seluruh model ditampilkan pada Tabel 3.

Setelah model BO-LSTM dibangun dan dievaluasi, langkah selanjutnya adalah melakukan peramalan untuk tiga bulan ke depan berdasarkan pola data sebelumnya. Model yang telah dilatih menggunakan parameter optimal hasil *Bayesian Optimization* digunakan untuk menghasilkan prediksi berkelanjutan (*rolling forecast*), dimulai dari data terakhir dalam *dataset* pelatihan. Prediksi ini dilakukan secara autoregresif, di mana hasil prediksi pada satu bulan digunakan sebagai *input* untuk memprediksi bulan berikutnya. Proses ini diulang hingga diperoleh prediksi selama tiga bulan ke depan. Hasil prediksi ini diharapkan dapat memberikan gambaran terhadap tren produksi yang akan datang dan menjadi dasar untuk perencanaan produksi serta pengelolaan persediaan herbisida.

Hasil dari peramalan tiga bulan ke depan pada bulan Januari hingga Maret 2024 ditunjukkan dalam grafik pada Gambar 7. Grafik tersebut memperlihatkan pola data uji, hasil prediksi pada data uji, serta proyeksi produksi selama periode Januari hingga Maret 2024. Berdasarkan grafik, model BO-LSTM memprediksi adanya tren penurunan produksi herbisida pada awal tahun. Pola ini sejalan dengan tren musiman tahunan sebelumnya yang menunjukkan penurunan permintaan dan produksi pada bulan yang sama. Meskipun prediksi pada sebagian titik masih menunjukkan fluktuasi yang tidak dapat dibaca dengan baik, namun secara umum model telah menunjukkan tingkat akurasi yang baik dengan nilai MAPE sebesar 7,81%. Hal ini mengindikasikan bahwa model BO-LSTM memiliki kemampuan yang andal dalam menangkap pola musiman dan tren jangka pendek. Oleh karena itu, hasil prediksi ini dapat dijadikan sebagai dasar yang kuat dalam pengambilan keputusan operasional, khususnya dalam perencanaan produksi dan pengelolaan stok herbisida, guna mengantisipasi potensi lonjakan atau penurunan permintaan musiman.

#### 4. Kesimpulan

Penelitian ini menunjukkan bahwa penerapan *Bayesian Optimization* mampu meningkatkan kinerja model LSTM dalam peramalan produksi herbisida bulanan. Model LSTM konvensional terbaik menghasilkan MAPE sebesar 11,33% dengan konfigurasi *n\_input* 12 dan 50 *epoch*, sedangkan model BO-LSTM menghasilkan performa lebih baik dengan MAPE sebesar 7,81%, MAE sebesar 37.588,61, dan RMSE sebesar 52.407,12. Hasil ini menunjukkan bahwa optimasi *hyperparameter* melalui *Bayesian Optimization* dapat membantu memperoleh konfigurasi model yang lebih sesuai dibandingkan percobaan manual pada LSTM konvensional.

Kontribusi utama penelitian ini adalah penerapan model BO-LSTM untuk peramalan produksi herbisida pada industri agrokimia dengan data historis produksi bulanan. Hasil penelitian menunjukkan bahwa BO-LSTM mampu

menangkap pola historis dan kecenderungan musiman produksi secara lebih baik dibandingkan LSTM konvensional. Prediksi tiga bulan ke depan, yaitu Januari hingga Maret 2024, menunjukkan kecenderungan penurunan produksi yang sejalan dengan pola musiman historis, sehingga hasil peramalan dapat digunakan sebagai masukan awal dalam perencanaan produksi dan pengelolaan persediaan.

Penelitian ini memiliki keterbatasan karena model yang dikembangkan bersifat univariat dan hanya menggunakan data historis produksi sebagai input. Variabel eksternal seperti curah hujan, suhu, luas tanam, indeks musim, harga komoditas, dan permintaan pasar belum dimasukkan ke dalam model. Oleh karena itu, model belum dapat menjelaskan hubungan kausal antara faktor eksternal dan perubahan produksi herbisida. Selain itu, jumlah data yang digunakan terbatas pada 60 data bulanan dari Januari 2019 hingga Desember 2023.

Penelitian selanjutnya dapat mengembangkan model *multivariate time series* dengan memasukkan variabel eksternal yang relevan, seperti data cuaca, luas tanam, indeks musim, permintaan pasar, dan harga komoditas pertanian. Selain itu, penelitian lanjutan dapat membandingkan BO-LSTM dengan metode lain, seperti SARIMA, XGBoost, GRU, Transformer, atau metode optimasi *hyperparameter* lain seperti Optuna, agar diperoleh pemahaman yang lebih komprehensif mengenai metode peramalan terbaik untuk produksi herbisida pada industri agrokimia.

## 5. Daftar Pustaka

- Abdalla, E. M. H., Pons, V., Stovin, V., De-Ville, S., Fassman-Beck, E., Alfredsen, K., & Muthanna, T. M. (2021). Evaluating different machine learning methods to simulate runoff from extensive green roofs. *Hydrology and Earth System Sciences*, 25(11), 5917–5935. <https://doi.org/10.5194/hess-25-5917-2021>
- Alam, M. S., Sultana, N., & Hossain, S. M. Z. (2021). Bayesian optimization algorithm based support vector regression analysis for estimation of shear capacity of FRP reinforced concrete members. *Applied Soft Computing*, 105, 107281. <https://doi.org/10.1016/j.asoc.2021.107281>
- Britania, R. (2022). DESIGN OF EXPERIMENT PADA ARTIFICIAL NEURAL NETWORK UNTUK MEMREDIKSI KURS TUKAR MATA UANG IDR/USD. *J@Ti Undip: Jurnal Teknik Industri*, 17(3), 219–228. <https://doi.org/10.14710/jati.17.3.219-228>
- Sinaga, H. D. E. (2022). Forecasting Techniques of Contact Herbicide Sales Using Single Moving Average Method in Ud. Lumbung Tani. *Jurnal Teknik Informatika (Jutif)*, 3(3), 473–478.
- Gautam, Y. (2022). Transfer Learning for COVID-19 cases and deaths forecast using LSTM network. *ISA Transactions*, 124, 41–56. <https://doi.org/10.1016/j.isatra.2020.12.057>
- Gharde, Y. (2015). Forecasting of herbicide consumption using autoregressive integrated moving average model. *Indian Journal of Weed Science*, 47(4), 408–410.
- Gu, Y. H., Jin, D., Yin, H., Zheng, R., Piao, X., & Yoo, S. J. (2022). Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM. *Agriculture*, 12(2), 256. <https://doi.org/10.3390/agriculture12020256>
- Hidayat, R., & Wibisonya, I. (2024). Rice price prediction with long short-term memory (LSTM) neural network. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 8(5), 658–664. <https://doi.org/10.29207/resti.v8i5.6041>
- Habib-ur-Rahman, M., Ahmad, A., Raza, A., Hasnain, M. U., Alharby, H. F., Alzahrani, Y. M., Bamagoos, A. A., Hakeem, K. R., Ahmad, S., Nasim, W., Ali, S., Mansour, F., & EL Sabagh, A. (2022). Impact of climate change on agricultural production; Issues, challenges, and opportunities in Asia. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.925548>
- Habtemariam, E. T., Kekeba, K., Martínez-Ballesteros, M., & Martínez-Álvarez, F. (2023). A Bayesian Optimization-Based LSTM Model for Wind Power Forecasting in the Adama District, Ethiopia. *Energies*, 16(5), 2317. <https://doi.org/10.3390/en16052317>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Keerthi, M. M., Sharmili, K. S., Arun, A., & Govindhasamy, R. (2023). Emerging Weed Problems under Changing Climatic Condition: A Review. *International Journal of Environment and Climate Change*, 13(7), 559–574. <https://doi.org/10.9734/ijec/2023/v13i71908>
- Kumar, V., Kumari, A., Price, A. J., Bana, R. S., Singh, V., & Bamboriya, S. D. (2023). Impact of Futuristic Climate Variables on Weed Biology and Herbicidal Efficacy: A Review. *Agronomy*, 13(2), 559. <https://doi.org/10.3390/agronomy13020559>
- Ya Ma, X., Tong, J., Jiang, F., Xu, M., Mei Sun, L., & Yan Chen, Q. (2023). Application of Deep Learning to Production Forecasting in Intelligent Agricultural Product Supply Chain. *Computers, Materials & Continua*, 74(3), 6145–6159. <https://doi.org/10.32604/cmc.2023.034833>
- Meng, H., Geng, M., & Han, T. (2023). Long short-term memory network with Bayesian optimization for health prognostics of lithium-ion batteries based on partial incremental capacity analysis. *Reliability Engineering & System Safety*, 236, 109288. <https://doi.org/10.1016/j.ress.2023.109288>
- Nugraha, E. S., Alika, Z., & Amir Hamzah, D. (2024). Forecasting the Stock Price of PT Astra International Using the LSTM Method. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 8(3), 431–437. <https://doi.org/10.29207/resti.v8i3.5699>
- Paramasivan, S. K. (2021). Deep Learning Based Recurrent Neural Networks to Enhance the Performance of Wind

- Energy Forecasting: A Review. *Revue d'Intelligence Artificielle*, 35(1), 1–10. <https://doi.org/10.18280/ria.350101>
- Priyambudi, Z. S., & Nugroho, Y. S. (2024). Which algorithm is better? An implementation of normalization to predict student performance. *VI INTERNATIONAL SCIENTIFIC CONVENTION OF UNIVERSIDAD TÉCNICA DE MANABÍ: Advances in Basic Sciences, Informatics and Applied Engineering*, 2994, 20110. <https://doi.org/10.1063/5.0182879>
- Rahmatillah, I., Sudirman, I., Azis, A. M., & Sudirman, I. D. (2024). Lstm Neural Networks with Bayesian Optimization for Reorder Simulation in Retail Inventory Management. *Journal of Theoretical and Applied Information Technology*, 102(22), 8193–8194.
- Ratna, Y., Swari, E. I., & Firmansyah, A. (2022). PERTUMBUHAN GULMA ALANG-ALANG (*Imperata cylindrica* L. Beauv.) PADA BERBAGAI KONDISI KEPADATAN SETELAH PEMOTONGAN DI PETROCHINA INTERNATIONAL JABUNG LTD. *Jurnal Media Pertanian*, 7(1), 50. <https://doi.org/10.33087/jagro.v7i1.135>
- Ruksaphon, N., & Olapiriyakul, S. (2024). *Demand forecasting for agrochemicals: fungicides, herbicides, and pesticides* (Doctoral dissertation, Thammasat University).
- Sabu, K. M., & Kumar, T. K. M. (2020). Predictive analytics in Agriculture: Forecasting prices of Arecanuts in Kerala. *Procedia Computer Science*, 171, 699–708. <https://doi.org/10.1016/j.procs.2020.04.076>
- SĂLCEANU, C., PARASCHIVU, M., COTUNA, O., SĂRĂȚEANU, V., PRIOTEASA, M. A., & FLONDOR, I. S. (2023). GLOBAL PESTICIDE MARKET: SIZE, TRENDS, FORECASTS. “Annals of the University of Craiova - Agriculture Montanology Cadastre Series”, 52(2), 146–157. <https://doi.org/10.52846/aamc.v52i2.1401>
- Snoek, J., Larochelle, H., & Adams, R. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25.
- Taslim, D. G., & Murwantara, I. M. (2024). Comparative analysis of ARIMA and LSTM for predicting fluctuating time series data. *Bulletin of Electrical Engineering and Informatics*, 13(3), 1943–1951. <https://doi.org/10.11591/eei.v13i3.6034>
- Torres, J. F., Hadjout, D., Sebaa, A., Martínez-Álvarez, F., & Troncoso, A. (2021). Deep Learning for Time Series Forecasting: A Survey. *Big Data*, 9(1), 3–21. <https://doi.org/10.1089/big.2020.0159>
- Din, M. S. U., Mubeen, M., Hussain, S., Ahmad, A., Hussain, N., Ali, M. A., El Sabagh, A., Elsabagh, M., Shah, G. M., Qaisrani, S. A., Tahir, M., Javeed, H. M. R., Anwar-ul-Haq, M., Ali, M., & Nasim, W. (2021). World Nations Priorities on Climate Change and Food Security. *Building Climate Resilience in Agriculture*, 365–384. [https://doi.org/10.1007/978-3-030-79408-8\\_22](https://doi.org/10.1007/978-3-030-79408-8_22)
- Wang, L., Derroncourt, F., & Bui, T. (2020). Bayesian optimization for selecting efficient machine learning models. *arXiv preprint arXiv:2008.00386*.
- Wasaya, A., Yasir, T. A., Sarwar, N., Atique-ur-Rehman, Mubeen, K., Rajendran, K., Hadifa, A., & Sabagh, A. E. L. (2022). Climate Change and Global Rice Security. *Modern Techniques of Rice Crop Production*, 13–26. [https://doi.org/10.1007/978-981-16-4955-4\\_2](https://doi.org/10.1007/978-981-16-4955-4_2)
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26–40.