

**OPTIMASI MODEL *EXTREME GRADIENT BOOSTING*
(XGBOOST) PADA SISTEM PREDIKSI PRODUKSI
JAGUNG BERBASIS WEB**

SKRIPSI

**Diajukan untuk memenuhi sebagian persyaratan mendapatkan gelar Strata
Satu Program Studi Informatika**



**FAISYA RIZKY ATHALAH
22EO10018**

**PROGRAM STUDI INFORMATIKA
FAKULTAS MATEMATIKA DAN ILMU KOMPUTER
UNIVERSITAS NAHDLATUL ULAMA AL GHAZALI
CILACAP
2026**

**OPTIMASI MODEL *EXTREME GRADIENT BOOSTING*
(XGBOOST) PADA SISTEM PREDIKSI PRODUKSI
JAGUNG BERBASIS WEB**

SKRIPSI

**Diajukan untuk memenuhi sebagian persyaratan mendapatkan gelar Strata
Satu Program Studi Informatika**



**FAISYA RIZKY ATHALAH
22EO10018**

**PROGRAM STUDI INFORMATIKA
FAKULTAS MATEMATIKA DAN ILMU KOMPUTER
UNIVERSITAS NAHDLATUL ULAMA AL GHAZALI
CILACAP
2026**

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Dengan ini saya menyatakan bahwa penulisan skripsi dengan judul “Optimasi Model *Extreme Gradient Boosting* (XGBoost) pada Sistem Prediksi Produksi Jagung Berbasis Web” adalah hasil karya saya dengan arahan dari pembimbing dan belum diajukan kepada pihak manapun. Sumber informasi yang dikutip dalam skripsi ini telah dicantumkan dalam Daftar Pustaka.

Demikian pernyataan ini dibuat dengan sebenarnya. Apabila di kemudian hari terdapat ketidaksesuaian dalam pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Cilacap, 27 Juli 2026



Faisya Rizky Athalah
22EO10018

LEMBAR PENGESAHAN

Skripsi Saudara

Nama : Faisya Rizky Athalah
NIM : 22EO10018
Fakultas/Prodi : Fakultas MIKOM / Prodi Informatika
Judul : Optimasi Model *Extreme Gradient Boosting* (XGBoost)
pada Sistem Prediksi Produksi Jagung Berbasis Web

Telah disidangkan oleh Dewan Penguji Fakultas Matematika dan Ilmu Komputer
Universitas Nahdlatul Ulama Al Ghazali (UNUGHA) Cilacap pada hari / tanggal :

Senin, 27 Juli 2026


Dan dapat diterima sebagai pemenuhan tugas akhir mahasiswa Program Strata Satu
(S.1) Prodi Informatika (S.Kom.) Fakultas Matematika dan Ilmu Komputer
(FMIKOM) pada Universitas Nahdlatul Ulama Al Ghazali (UNUGHA) Cilacap.


Cilacap, 3 Agustus 2026

Dewan Sidang

Ketua


Sekretaris



M.T.A. Aziz Zein, S.Si., M.Kom.
NIDN. 2125098601


Tri Anggoro, M.Kom.
NIDN. 0601128103

Penguji 1


Penguji 2



Tri Anggoro, M.Kom.
NIDN. 0601128103


Eri Nur Shofi'i, S.H., M.A.
NIDN. 0602029501

Pembimbing I


Pembimbing II


M.T.A. Aziz Zein, S.Si., M.Kom.
NIDN. 2125098601


Dr. M. Khanif, M.Pd.B.I.
NIDN. 0617058703

Mengetahui,
Dekan Fakultas Matematika dan Ilmu Komputer




M.T.A. Aziz Zein S.Si., M.Kom.
NIDN. 2125098601

HALAMAN NOTA KONSULTAN

NOTA KONSULTAN

Hal : Skripsi Saudari Faisya Rizky Athalah
Lampiran : -

Kepada
Yth. Dekan Fakultas Matematika dan Ilmu Komputer
Universitas Nahdlatul Ulama Al Ghazali Cilacap
di Cilacap

Assalamu'alaikum Wr. Wb.

Setelah membaca, memeriksa dan melakukan perbaikan seperlunya maka skripsi saudara/i:

Nama : Faisya Rizky Athalah
NIM : 22EO10018
Fakultas / Prodi : Fakultas Matematika dan Ilmu Komputer / Prodi
Informatika
Judul : Optimasi Model *Extreme Gradient Boosting* (XGBoost)
pada Sistem Prediksi Produksi Jagung Berbasis Web

Dapat diajukan ke Fakultas Matematika dan Ilmu Komputer, Universitas Nahdlatul Ulama Al Ghazali Cilacap untuk memenuhi syarat memperoleh gelar Strata Satu (S1).

Wassalamu'alaikum Wr. Wb.

Cilacap, 3 Agustus 2026

Konsultan



Tri Anggoro, M.Kom
NIDN. 0601128103

NOTA PEMBIMBING

Cilacap, 24 Juli 2026

Kepada Yth :
Fakultas Matematika dan Komputer (FMIKOM)
UNUGHA Cilacap
di Cilacap

Assalamu'alaikum Wr. Wb.

Setelah melakukan bimbingan, telaah, arahan dan koreksi tahap penulisan skripsi saudara:

Nama : Faisya Rizky Athalah
NIM : 22EO10018
Fakultas : Matematika dan Ilmu Komputer
Prodi : Informatika
Judul : Optimasi Model *Extreme Gradient Boosting* (XGBoost) pada Sistem Prediksi Produksi Jagung Berbasis Web

Kami berpendapat bahwa skripsi tersebut sudah dapat diajukan ke sidang skripsi. Bersamaan ini kami kirimkan skripsi tersebut, semoga dapat segera disidangkan.

Atas perhatiannya kami ucapkan terima kasih.
Wassalamu'alaikum Wr. Wb.

Mengetahui

Pembimbing I


M. T. Abdul Aziz Zein, S.Si., M.Kom.
NIDN 2125098601

Pembimbing II


Dr. M. Khanif, M.Pd.B.I
NIDN 0617058703

HALAMAN MOTO

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”
(QS. Al-Baqarah : 286)

“Jangan pernah takut sendiri, sebab matahari pun tetap mampu bersinar terang
meskipun sendiri”

(Bravyson Vconk)

“Aku akan terus melangkah, bukan karena aku tidak pernah lelah, tetapi karena
ada harapan kedua orang tua yang harus kuperjuangkan.”

(FRA)

HALAMAN PERSEMBAHAN

Segala puji bagi Allah SWT, Rabb semesta alam yang senantiasa memberikan karunia sehingga penulis mampu menyelesaikan penulisan skripsi ini. Karya ini saya persembahkan kepada :

1. Cinta pertama saya, Ayah EN, S.Kom dan pintu surga saya, Ibu SM, S.E., terima kasih atas setiap doa yang selalu mengiringi langkah penulis, atas kasih sayang yang tidak pernah berkurang, serta pengorbanan yang mungkin tidak akan pernah mampu penulis balas sepenuhnya. Kalian adalah alasan penulis tetap kuat ketika lelah, tetap bangkit ketika gagal, dan tetap percaya bahwa setiap perjuangan akan menemukan hasilnya. Di balik setiap proses yang penulis lalui, ada air mata, harapan, dan ketulusan kalian yang selalu menjadi penguat dalam hidup penulis. Terima kasih karena tidak pernah berhenti percaya kepada penulis, bahkan di saat penulis meragukan diri sendiri.
2. Almarhum Kakek tercinta, yang meskipun telah lebih dahulu berpulang, namun jejak dan semangatnya tidak pernah benar-benar pergi dari kehidupan penulis. Terima kasih karena telah menjadi sosok yang menginspirasi penulis untuk terus belajar dan berani bermimpi. Hari ini, selesainya skripsi ini menjadi salah satu langkah kecil penulis untuk meneruskan semangat kakek dalam berkarya dan belajar di bidang teknologi. Penulis berharap dapat melanjutkan perjuangan itu, membangun karier yang membanggakan. Meskipun kakek tidak dapat menyaksikan momen ini secara langsung, penulis percaya bahwa setiap langkah yang ditempuh hingga hari ini adalah bagian dari doa dan semangat yang kakek tinggalkan. Hari ini, gelar yang sama akhirnya berhasil penulis raih sebagai bentuk penghormatan atas perjuangan yang telah kakek tinggalkan.
3. S.Arafi.M, sosok kakak yang selalu memberikan doa, dukungan, dan semangat tanpa henti dalam setiap langkah penulis. Terima kasih karena selalu hadir sebagai tempat berbagi cerita, memberikan kekuatan di saat penulis merasa lelah, serta menjadi pengingat untuk tetap percaya dan bertahan dalam setiap proses yang dijalani. Dukungan dan perhatian yang diberikan menjadi salah satu bagian berharga yang mengiringi perjalanan penulis hingga karya ini dapat terselesaikan.
4. Devi Saputri, terima kasih telah menjadi bagian dari perjalanan hidup penulis sejak masa SMK hingga akhirnya penulis berada di titik ini. Meskipun kini kita jarang bertemu, doa, dukungan, dan semangatmu selalu penulis rasakan. Terima kasih karena tidak pernah lelah percaya dan mendoakan setiap langkah penulis. Semoga segala kebaikan yang telah kamu berikan dibalas dengan kebahagiaan, kesehatan, dan kesuksesan. Terima kasih telah menjadi sahabat yang selalu memiliki tempat istimewa dalam setiap perjalanan ini.
5. Tribe (Depio dan Sopia), terima kasih telah menjadi teman pertama yang penulis temui di bangku perkuliahan, sekaligus menjadi teman yang tetap bertahan

hingga hari ini. Terima kasih untuk setiap cerita, tawa, dukungan, dan kebersamaan yang telah kita lewati selama perjalanan kuliah.

6. Robbi, Rheika, dan Bela, yang selalu kebersamai setiap proses perjalanan penulis dengan penuh cerita, dukungan, dan ketulusan sebagai sahabat. Terima kasih karena selalu hadir di saat senang maupun sulit, menjadi tempat berbagi keluh kesah, serta menghadirkan tawa yang menguatkan di tengah lelahnya perjuangan. Kehadiran kalian menjadi salah satu alasan penulis tetap bertahan dan mampu menyelesaikan perjalanan ini hingga akhir.
7. TripleKill dan BMKG Squad, Terima kasih karena sejak awal dipertemukan hingga hari ini, kalian tidak pernah berhenti menjadi tempat pulang di tengah lelahnya proses yang penulis jalani. Terima kasih atas setiap tawa yang mampu menghapus penat, setiap candaan yang menghidupkan kembali semangat, setiap bantuan tanpa diminta, dan setiap kalimat sederhana yang ternyata begitu berarti ketika penulis hampir menyerah.
8. Teman-teman Informatika A, yang telah menjadi bagian dari perjalanan penulis selama masa perkuliahan. Terima kasih atas kebersamaan, dukungan, semangat, serta berbagai cerita dan pengalaman yang telah dilewati bersama.
9. Keluarga besar Himafortic, yang telah menjadi tempat bagi penulis untuk belajar, bertumbuh, dan berkembang selama menjalani proses perkuliahan. Terima kasih atas setiap pengalaman, kebersamaan, serta dukungan yang diberikan, sehingga penulis dapat mengenal banyak hal baru dan menjadi pribadi yang lebih baik. Segala cerita dan perjalanan yang telah dilewati bersama akan selalu menjadi kenangan berharga bagi penulis.
10. Terakhir, karya ini penulis persembahkan untuk diri sendiri. Terima kasih karena telah memilih untuk tetap bertahan hingga sejauh ini, meskipun perjalanan yang dilalui tidak selalu mudah. Terima kasih karena tidak menyerah ketika rasa lelah, ragu, takut, dan keinginan untuk berhenti datang silih berganti. Terima kasih karena tetap bangkit setiap kali jatuh, tetap melangkah meski tertatih, serta tetap percaya bahwa setiap doa dan perjuangan pada akhirnya akan menemukan jalannya. Untuk setiap malam yang dipenuhi kecemasan, setiap air mata yang jatuh dalam diam, setiap pengorbanan yang mungkin tidak pernah diketahui orang lain, serta setiap usaha yang sering kali terasa sia-sia, semuanya telah mengantarkan penulis hingga berada di titik ini. Semoga ketika suatu saat nanti penulis kembali merasa lemah atau meragukan diri sendiri, karya ini menjadi pengingat bahwa penulis pernah melewati begitu banyak hal yang dahulu terasa mustahil dan berhasil bertahan hingga akhir. Terima kasih karena telah berjuang dengan segenap hati. Hari ini, semua perjuangan itu telah menjadi bukti bahwa tidak ada usaha yang benar-benar sia-sia.

KATA PENGANTAR

Puji syukur kepada Allah SWT atas segala limpahan nikmat dan karuniaNya, sehingga penulis dapat menyelesaikan penulisan skripsi yang berjudul: “Optimasi Model *Extreme Gradient Boosting* (XGBoost) pada Sistem Prediksi Produksi Jagung Berbasis Web”

Tentunya, skripsi ini tidak akan selesai tanpa adanya bantuan dari banyak pihak, karena itu penulis menyampaikan terima kasih kepada :

1. Bapak M.T. Abdul Aziz Zein, S.Si., M.Kom., Dekan Fakultas Matematika dan Ilmu Komputer sekaligus dosen pembimbing I, yang telah memberikan kesempatan menimba ilmu dan dukungan selama proses studi sampai tahap penulisan skripsi ini.
2. Bapak Dr. M. Khanif, M.Pd.B.I, pembimbing II yang dengan sabar memberikan bimbingan dan petunjuk dalam menyelesaikan skripsi ini.
3. Bapak Tri Anggoro, M.Kom., Kaprodi Informatika yang telah memberikan banyak ilmu selama masa studi ini.
4. Bapak Bagus Pramujio, S.Si., M.Sc., selaku Kepala Stasiun Meteorologi Tunggul Wulung Cilacap yang telah memberikan izin, dukungan, serta membantu dalam penyediaan data iklim yang digunakan dalam penelitian ini.
5. Bapak Adnan Dendy Mardika, S.Kom., M.Si., selaku pembimbing lapangan yang telah memberikan arahan, masukan, serta dukungan dalam proses penelitian.
6. Stasiun Meteorologi Tunggul Wulung Cilacap yang telah menyediakan data iklim serta memberikan dukungan selama pelaksanaan penelitian.
7. Dinas Pertanian Kabupaten Cilacap yang telah menyediakan data produksi jagung sebagai data utama dalam penelitian ini.
8. Bapak-Ibu dosen Program Studi Informatika Fakultas Matematika dan Ilmu Komputer Universitas Nahdlatul Ulama Al Ghazali Cilacap
9. Semua pihak yang tidak dapat kami sebutkan satu persatu

Semoga Allah SWT membalas jerih payah dan pengorbanan yang telah diberikan dengan balasan yang lebih baik. Amiin. Penulis berharap semoga karya kecil ini bermanfaat bagi pembaca.

Cilacap, 27 Juli 2026

Penulis



Faisya Rizky Athalah

ABSTRAK

FAISYA RIZKY ATHALAH. Optimasi Model *Extreme Gradient Boosting* (XGBoost) pada Sistem Prediksi Produksi Jagung Berbasis Web. Dibimbing oleh MOCHAMAD T. A. AZIZ ZEIN, S.Si., M.Kom dan Dr. M. KHANIF, M.Pd.B.I.

Produksi jagung merupakan salah satu komoditas pertanian yang memiliki peran penting dalam mendukung ketahanan pangan dan perekonomian daerah. Namun, produksi jagung sangat dipengaruhi oleh kondisi iklim yang bersifat dinamis, seperti lama penyinaran matahari, curah hujan, suhu udara, kelembaban udara, serta fenomena *El Niño Southern Oscillation* (ENSO) yang direpresentasikan melalui *Oceanic Niño Index* (ONI). Perubahan kondisi iklim tersebut dapat menyebabkan fluktuasi hasil produksi sehingga diperlukan suatu metode yang mampu memprediksi produksi jagung secara akurat. Penelitian ini bertujuan untuk menganalisis pengaruh optimasi *hyperparameter* terhadap kinerja algoritma *Extreme Gradient Boosting* (XGBoost) dalam prediksi produksi jagung serta mengimplementasikan model yang dihasilkan ke dalam sistem berbasis web sebagai alat bantu perencanaan produksi. Data yang digunakan meliputi data produksi jagung, lama penyinaran matahari, curah hujan, suhu, kelembaban, dan ONI periode tahun 2020–2024. Proses pemodelan dilakukan dengan membandingkan model XGBoost *Baseline* dan model XGBoost yang dioptimasi menggunakan metode *Random Search*. Evaluasi model dilakukan menggunakan metrik *Mean Absolute error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2).

Hasil penelitian menunjukkan bahwa model XGBoost *Baseline* menghasilkan nilai MAE sebesar 772,09 ton, RMSE sebesar 1927,52 ton, dan R^2 sebesar 0,887. Setelah dilakukan optimasi *hyperparameter* menggunakan *Random Search*, performa model mengalami peningkatan dengan nilai MAE sebesar 748,08 ton, RMSE sebesar 1876,00 ton, dan R^2 sebesar 0,893. Hasil tersebut menunjukkan bahwa optimasi *hyperparameter* mampu meningkatkan akurasi prediksi dan kemampuan model dalam menjelaskan variasi data produksi jagung. Model terbaik kemudian diintegrasikan ke dalam sistem prediksi berbasis web menggunakan *framework FastAPI* dan *database Supabase*. Hasil pengujian menggunakan metode *Black Box Testing* menunjukkan bahwa seluruh fungsi sistem berjalan sesuai dengan kebutuhan yang telah ditetapkan. Dengan demikian, penelitian ini berhasil menghasilkan model prediksi produksi jagung yang memiliki performa baik serta dapat diimplementasikan ke dalam sistem berbasis web untuk mendukung proses prediksi dan perencanaan produksi jagung.

Kata kunci : *FastAPI*, Prediksi, Produksi Jagung, *Random Search*, Website, XGBoost

ABSTRACT

FAISYA RIZKY ATHALAH. Optimasi Model *Extreme Gradient Boosting* (XGBoost) pada Sistem Prediksi Produksi Jagung Berbasis Web. Supervised by MOCHAMAD T. A. AZIZ ZEIN, S.Si., M.Kom and Dr. M. KHANIF, M.Pd.B.I.

Corn production is one of the agricultural commodities that plays a crucial role in supporting food security and the regional economy. However, corn production is highly influenced by dynamic climate conditions, such as sunshine duration, rainfall, air temperature, air humidity, and the El Niño Southern Oscillation (ENSO) phenomenon, represented by the Oceanic Niño Index (ONI). These changes in climate conditions can lead to production fluctuations, necessitating a method capable of predicting corn production accurately. This study aims to analyze the effect of hyperparameter optimization on the performance of the Extreme Gradient Boosting (XGBoost) algorithm in predicting corn production and to implement the resulting model into a web-based system as a tool for production planning. The data used include corn production, sunshine duration, rainfall, temperature, humidity, and ONI for the 2020–2024 period. The modeling process was conducted by comparing a Baseline XGBoost model with an XGBoost model optimized using the Random Search method. The model evaluation was performed using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination (R^2).

The results showed that the Baseline XGBoost model produced an MAE of 772.09 tons, an RMSE of 1927.52 tons, and an R^2 of 0.887. After hyperparameter optimization using Random Search, the model's performance improved, achieving an MAE of 748.08 tons, an RMSE of 1876.00 tons, and an R^2 of 0.893. These results demonstrate that hyperparameter optimization can improve prediction accuracy and the model's ability to explain variations in corn production data. The best model was then integrated into a web-based prediction system using the FastAPI framework and a Supabase database. Testing using the Black Box Testing method showed that all system functions operated according to the established requirements. Consequently, this study has successfully produced a corn production prediction model with high performance that can be implemented into a web-based system to support the prediction and production planning processes.

Keywords: Corn Production, FastAPI, Prediction, Random Search, Website, XGBoost

DAFTAR ISI

HALAMAN PERNYATAAN KEASLIAN SKRIPSI	iii
LEMBAR PENGESAHAN	iv
HALAMAN NOTA KONSULTAN.....	v
HALAMAN MOTO	vii
HALAMAN PERSEMBAHAN	viii
KATA PENGANTAR	x
ABSTRAK.....	xi
DAFTAR ISI.....	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL.....	xvi
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah.....	2
C. Batasan Masalah	3
D. Tujuan Penelitian	3
E. Manfaat Penelitian	3
BAB II TINJAUAN PUSTAKA	4
A. Penelitian Terkait	4
B. Landasan Teori.....	10
BAB III METODOLOGI.....	17
A. Waktu dan Tempat Penelitian.....	17
B. Alat dan Bahan.....	17
C. Prosedur Penelitian	18
D. Jadwal Penelitian	37
BAB IV HASIL DAN PEMBAHASAN.....	39
A. Hasil	39
B. Pembahasan.....	52
BAB V KESIMPULAN.....	57
A. Kesimpulan	57
B. Saran	57
DAFTAR PUSTAKA	59

LAMPIRAN	65
----------------	----

DAFTAR GAMBAR

Gambar 1 Mindmap Penelitian	9
Gambar 2 Prototyping Method.....	16
Gambar 3 Alur Penelitian.....	19
Gambar 4 Diagram Alur Optimasi	25
Gambar 5 Use Case Diagram	28
Gambar 6 Activity Diagram User	29
Gambar 7 Activity Diagram Admin.....	30
Gambar 8 Sequence Diagram User	31
Gambar 9 Sequence Diagram Admin	32
Gambar 10 Gantt Chart Jadwal Peneliti	38
Gambar 11 Matriks Korelasi.....	41
Gambar 12 Grafik Prediksi Produksi Jagung Baseline	42
Gambar 13 Grafik Optimasi Prediksi Produksi Jagung	43
Gambar 14 Arsitektur Sistem Prediksi.....	45
Gambar 15 Halaman Utama.....	48
Gambar 16 Halaman Prediksi Jagung	48
Gambar 17 Halaman Prediksi Jagung (Grafik Perbandingan)	48
Gambar 18 Halaman Prediksi Jagung (Hasil Prediksi).....	49
Gambar 19 Halaman Prediksi Jagung (Hasil Rekomendasi)	49
Gambar 20 Halaman Login Admin.....	50
Gambar 21 Halaman Dashboard Admin	50
Gambar 22 Halaman Kelola Prediksi.....	51
Gambar 23 Halaman Kelola Dataset Produksi.....	51
Gambar 24 Halaman Simulasi Prediksi	52

DAFTAR TABEL

Tabel 1 Tabel Penelitian Terkait	4
Tabel 2 Alat dan Bahan.....	17
Tabel 3 Hasil Evaluasi Model	26
Tabel 4 Skenario Pengujian User	34
Tabel 5 Skenario Pengujian Admin	35
Tabel 6 Spesifikasi Data.....	39
Tabel 7 Contoh Data yang diambil	39
Tabel 8 Struktur Database	46
Tabel 9 Hasil Uji Normalitas Shapiro-Wilk.....	54
Tabel 10 Hasil Uji <i>Wilcoxon Signed-Rank Test</i>	54
Tabel 11 Hasil Pengujian User.....	65
Tabel 12 Hasil Pengujian Admin	67

BAB I PENDAHULUAN

A. Latar Belakang

Jagung merupakan salah satu komoditas pertanian strategis di Indonesia yang memiliki nilai ekonomi tinggi serta berperan sebagai sumber karbohidrat dan protein utama setelah padi[1]. Kabupaten Cilacap merupakan salah satu wilayah di Provinsi Jawa Tengah dengan tingkat produksi jagung yang relatif tinggi, meskipun belum termasuk daerah dengan produksi terbesar di tingkat provinsi. Tingkat produksi jagung di suatu wilayah dipengaruhi oleh berbagai faktor, baik aspek teknis budidaya maupun faktor lingkungan[2]. Di antara berbagai faktor yang memengaruhi produksi jagung, unsur iklim seperti curah hujan, suhu udara, kelembapan, serta durasi penyinaran matahari memiliki kontribusi yang signifikan terhadap proses pertumbuhan dan tingkat produktivitas tanaman jagung[3][4]. Meskipun demikian, kondisi iklim bersifat dinamis dan pada periode tertentu dapat mengalami anomali atau kejadian ekstrem, seperti kenaikan suhu, kekeringan, maupun curah hujan yang berlebihan, sehingga berpotensi menimbulkan fluktuasi produksi jagung dari waktu ke waktu[5]. Hubungan antarvariabel iklim tersebut memiliki karakter yang kompleks, saling memengaruhi, dan cenderung bersifat nonlinier. Kondisi ini menyebabkan proses analisis serta prediksi produksi jagung yang dilakukan secara manual maupun dengan pendekatan statistik konvensional menjadi kurang mampu menangkap pola hubungan yang sebenarnya secara akurat[6][7][8].

Machine learning merupakan pendekatan komputasional yang memungkinkan sistem untuk mengidentifikasi pola dari data historis, seperti variabel iklim dan hasil panen, sehingga mampu menghasilkan model prediksi dengan tingkat ketepatan yang lebih baik[9]. Dalam bidang pertanian, metode ini telah banyak dimanfaatkan dalam penelitian prediksi produksi karena kemampuannya dalam merepresentasikan hubungan antarvariabel yang kompleks dan bersifat nonlinier secara lebih efektif[10]. Sejumlah penelitian menunjukkan bahwa algoritma *machine learning* mampu menghasilkan tingkat kesalahan prediksi yang lebih rendah dibandingkan metode statistik konvensional, seperti regresi linear. Salah satu model *machine learning* yang menunjukkan kinerja sangat optimal adalah algoritma *Extreme Gradient Boosting* (XGBoost)[11][12][13].

XGBoost merupakan algoritma *ensemble* berbasis *decision tree* yang menggunakan pendekatan *gradient boosting*, dirancang untuk memberikan efisiensi komputasi dan kecepatan proses yang tinggi[14]. Algoritma ini memiliki kemampuan yang unggul dalam memodelkan pola nonlinier antarvariabel iklim seperti suhu, curah hujan, kelembapan, lama penyinaran, serta indeks fenomena

iklim global seperti ONI (*Oceanic Niño Index*), sehingga mampu menghasilkan prediksi dengan tingkat presisi yang lebih tinggi dibandingkan algoritma lainnya[7][15][16].

Meskipun XGBoost memiliki kemampuan unggul dalam memodelkan pola nonlinier dan interaksi kompleks antarvariabel, performa model sangat dipengaruhi oleh pemilihan *hyperparameter*. Optimasi *hyperparameter* dilakukan untuk meningkatkan performa masing-masing model, termasuk XGBoost, dengan tujuan memperoleh prediksi yang lebih akurat dan stabil[17][18][19][20]. Penentuan nilai *hyperparameter* yang optimal, seperti jumlah pohon (*n_estimators*), kedalaman maksimum pohon (*max_depth*), *learning rate*, serta parameter regularisasi, dilakukan melalui proses optimasi menggunakan metode *Random Search*[21]. Pendekatan ini memungkinkan model menangkap pola nonlinier dan interaksi kompleks antarvariabel iklim secara lebih efektif, sekaligus mengontrol kompleksitas model sehingga dapat meminimalkan risiko *overfitting* dan meningkatkan kemampuan generalisasi dalam menghasilkan prediksi[22][23].

Berdasarkan uraian tersebut, dapat diketahui bahwa fluktuasi produksi jagung dipengaruhi oleh faktor iklim yang bersifat dinamis serta memiliki hubungan yang kompleks antarvariabelnya. Beberapa penelitian sebelumnya telah memanfaatkan metode *machine learning* untuk melakukan prediksi produksi pertanian, namun penerapan algoritma XGBoost pada prediksi produksi jagung yang disertai dengan proses optimasi *hyperparameter* secara sistematis masih relatif terbatas. Oleh karena itu, penelitian ini menawarkan kebaruan berupa penerapan model XGBoost yang dioptimasi menggunakan metode *Random Search*, sehingga diharapkan mampu menghasilkan model prediksi yang lebih akurat dan stabil. Selain itu, model yang dihasilkan juga diimplementasikan dalam sistem prediksi berbasis *web* sehingga dapat digunakan secara lebih praktis sebagai alat bantu dalam mendukung perencanaan produksi jagung.

B. Rumusan Masalah

Berdasarkan Latar Belakang, maka didapatkan perumusan masalah sebagai berikut:

1. Bagaimana pengaruh optimasi *hyperparameter* terhadap kinerja model XGBoost pada prediksi produksi jagung?
2. Bagaimana model XGBoost yang telah dioptimasi dapat diintegrasikan ke dalam sistem prediksi produksi jagung berbasis web agar dapat digunakan secara efisien sebagai alat bantu perencanaan produksi?

C. Batasan Masalah

Batasan masalah membahas mengenai :

1. Penelitian ini hanya berfokus pada komoditas Jagung, dengan data yang digunakan mencakup variabel independen (lama penyinaran matahari, curah hujan, suhu, kelembaban, dan Indeks ENSO) dan variabel dependen (produksi jagung) selama 5 tahun secara bulanan, serta hanya mencakup wilayah Kabupaten Cilacap, sehingga generalisasi hasil terbatas pada dataset tersebut..
2. Proses optimasi dalam penelitian ini difokuskan pada penyesuaian lima *hyperparameter* model XGBoost, yaitu *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree* dengan menggunakan metode *Random Search* untuk memperoleh performa model yang optimal dalam melakukan prediksi produksi jagung.
3. Model yang dikembangkan dalam penelitian ini merupakan model prediksi yang mempelajari pola dari data historis produksi jagung dan variabel iklim periode 2020–2024.
4. Model prediksi diimplementasikan dalam sistem berbasis web menggunakan bahasa pemrograman *Python* dengan *framework FastAPI*.

D. Tujuan Penelitian

Tujuan penelitian berdasarkan rumusan masalah diatas adalah:

1. Mengetahui sejauh mana optimasi *hyperparameter* pada algoritma XGBoost dapat meningkatkan akurasi prediksi produksi jagung.
2. Mengetahui cara integrasi model XGBoost yang telah dioptimasi ke dalam sistem prediksi produksi jagung berbasis web.

E. Manfaat Penelitian

Manfaat teoritis dalam penelitian ini adalah:

1. Memberikan pemahaman lebih mendalam mengenai pengaruh optimasi *hyperparameter* pada algoritma XGBoost dalam prediksi produksi jagung.
2. Menjadi referensi bagi penelitian selanjutnya yang ingin mengkaji penerapan algoritma *machine learning* untuk prediksi hasil pertanian berbasis data iklim dan fenomena cuaca global.

Manfaat praktis dalam penelitian ini yaitu:

1. Mengetahui cara menerapkan dan mengoptimasi algoritma XGBoost untuk prediksi produksi jagung.
2. Mengetahui proses integrasi model *machine learning* ke dalam sistem berbasis web menggunakan bahasa pemrograman *Python*.
3. Sebagai alat bantu perencanaan produksi jagung berbasis web yang dapat meningkatkan efisiensi dan akurasi prediksi hasil panen bagi instansi terkait seperti BMKG dan Dinas Pertanian.

BAB II TINJAUAN PUSTAKA

A. Penelitian Terkait

Berikut penelitian terkait penerapan optimasi algoritma XGBoost dalam prediksi produksi jagung.

Tabel 1 Tabel Penelitian Terkait

No	Nama (Tahun)	Keterangan Penelitian
(1)	(2)	(3)
1	[[Wijaya H, Pramana Hostiadi D, Triandini E, 2024]	Judul: Meningkatkan Prediksi Penjualan Retail Xyz dengan Teknik Optimasi <i>Random Search</i> pada Model XGBoost Metode: Menggunakan algoritma XGBoost dan optimasi menggunakan teknik <i>Random Search</i> untuk memperoleh kombinasi <i>hyperparameter</i> terbaik Hasil: Optimasi dengan <i>Random Search</i> meningkatkan nilai R^2 dari 96,50% menjadi 97,21%, serta menurunkan nilai MSE dan MAE, yang menunjukkan peningkatan akurasi prediksi penjualan setelah proses tuning
2	[Setiawan N, Zakaria H, 2026]	Judul: Implementasi <i>Bayesian Optimization</i> untuk Meningkatkan Akurasi Prediksi Penjualan Menggunakan Algoritma XGBoost (Studi Kasus: CV XYZ) Metode: Menggunakan algoritma XGBoost yang dioptimalkan dengan <i>Bayesian Optimization</i> Hasil: Penerapan <i>Bayesian Optimization</i> pada algoritma XGBoost mampu meningkatkan kinerja prediksi penjualan dibandingkan konfigurasi parameter standar, sebagaimana ditunjukkan oleh perbaikan nilai MAE, RMSE, dan koefisien determinasi (R^2).

No	Nama (Tahun)	Keterangan Penelitian
(1)	(2)	(3)
3	[Haris et al. 2025]	Judul: Peningkatan Akurasi Prediksi Harga Barang Impor Menggunakan XGBoost dan <i>Particle Swarm Optimization</i> Metode: Algoritma XGBoost dan Optimasi <i>hyperparameter</i> XGBoost menggunakan <i>Particle Swarm Optimization</i> (PSO) Hasil: <i>Hyperparameter</i> terbaik untuk XGBoost ditemukan dengan nilai Max-depth 51,49, <i>subsample</i> 0,89, dan Min_child_weight 0,65, yang meningkatkan akurasi prediksi menjadi 14,6%.
4	[Tiastama A, Budi I, 2024]	Judul: View of Comparison Between <i>Random Search</i> and Genetic Algorithm in XGBoost <i>Hyperparameter</i> Tuning for Retail Sales Forecasting Metode: Membandingkan dua teknik optimasi <i>hyperparameter</i> pada model XGBoost, yaitu <i>Random Search</i> dan <i>Genetic Algorithm</i> (GA), untuk prediksi penjualan retail. Hasil: <i>Genetic Algorithm</i> menghasilkan performa yang lebih baik dibandingkan <i>Random Search</i> dalam meningkatkan akurasi XGBoost, ditunjukkan dengan nilai R² lebih tinggi serta RMSE dan MAE lebih rendah.
5	[Hikmah A, 2025]	Judul: Optimasi <i>Hyperparameter Ensemble Learning</i> untuk Prediksi Penyakit Liver Berdasarkan Data Pasien Metode: Metodologi CRISP-DM (<i>Cross-Industry Standard Process for Data Mining</i>) Hasil: Dari hasil eksperimen, <i>Extra Trees Classifier</i> terbukti menjadi model terbaik, dengan akurasi tertinggi (73.61%) dan AUC

No	Nama (Tahun)	Keterangan Penelitian
(1)	(2)	(3)
		76.82%, serta memiliki keseimbangan optimal antara <i>recall</i> (89.82%) dan <i>precision</i> (77.22%).
6	[Tribuana et al. 2025]	Judul: Penerapan Algoritma XGBoost Untuk Prediksi Kepuasan Pelanggan pada Layanan E-Commerce: Studi pada Dataset Transaksi Nyata Metode: Pendekatan kuantitatif dengan <i>machine learning</i> prediktif menggunakan XGBoost. Hasil: XGBoost lebih unggul dibanding Random Forest & Logistic Regression. Akurasi: 92,4%, F1-Score: 90,6%, ROC-AUC: 0,941
7	[Wirda Z, Ramadhani A, 2025]	Judul: Model Prediksi Produksi Pertanian Berbasis <i>Machine learning</i> dan Data Lapangan Metode: <i>Random Forest</i>, <i>Support Vector Regression</i>, <i>Extreme Gradient Boosting</i> (XGBoost), dan <i>Artificial Neural Network</i> Hasil: Diantara algoritma yang diuji, XGBoost menunjukkan performa terbaik dengan nilai R^2 sebesar 0,89 dan RMSE 0,52 ton/ha pada dataset pengujian, serta mempertahankan kinerja yang konsisten pada validasi lapangan musim tanam berikutnya (RMSE 0,61 ton/ha).
8	[Li et al. 2025]	Judul: Application of XGBoost Model and Multi-Source Data for Winter Wheat Yield Prediction Metode: Menggunakan algoritma <i>Extreme Gradient Boosting</i> (XGBoost) untuk memprediksi hasil panen gandum musim

No	Nama (Tahun)	Keterangan Penelitian
(1)	(2)	(3)
		Hasil: Model XGBoost menunjukkan performa prediksi terbaik dibandingkan model pembanding, dengan nilai R^2 lebih tinggi dan RMSE serta MAE lebih rendah.
9	[Marchanda Izzati P, Fitriyani F, 2025]	Judul: Implementasi Algoritma XGBoost untuk Prediksi Capaian Bulanan Pendapatan Daerah Kota Bandung Metode: Penelitian kuantitatif dengan pendekatan prediktif menggunakan algoritma XGBoost Hasil: Algoritma XGBoost <i>Regressor</i> efektif dalam membangun model prediksi capaian Pendapatan Asli Daerah (PAD) Kota Bandung berdasarkan data historis. Model memberikan hasil akurat dengan nilai MAE sebesar 5,6M, RMSE 9,3M, dan R^2 sebesar 0,73 pada data uji
10	[Safii et al. 2025]	Judul: Model Prediksi Penjadwalan Produksi Energi Terbarukan dengan Algoritma XGBoost dan Analisis Interpretatif Menggunakan SHAP Metode: Algoritma XGBoost Hasil: Algoritma XGBoost dapat secara efektif memahami pola dalam data dan memberikan hasil prediksi yang akurat dengan nilai MSE tercatat sebesar 23.738,02, yang merepresentasikan kesalahan kuadrat rata-rata dalam memprediksi model dibandingkan dengan nilai aktual.
11	[[Pangestu A, Mujiyono S, 2025]	Judul: Implementasi Algoritma XGBoost Untuk Prediksi Status Gizi Balita Berbasis Website Metode: Pendekatan kuantitatif dengan metode penelitian terapan (<i>applied</i>)

No	Nama (Tahun)	Keterangan Penelitian
(1)	(2)	(3)
		<i>research</i>), metodologi penelitian yang berorientasi pada aplikasi. Hasil: Penelitian ini berhasil mengembangkan sistem prediksi status gizi balita menggunakan algoritma XGBoost dengan tingkat akurasi yang sangat baik mencapai 97,17 persen. Model yang dikembangkan mampu mengklasifikasikan tiga kategori status gizi (Normal, Lebih, Buruk) berdasarkan data antropometri dengan presisi 97,16 persen, recall 97,17 persen, dan F1-score 97,16 persen.
12	[Syahadah F, Subagio R, Rizqiyah P, 2025]	Judul: Penerapan XGBoost Dalam Prediksi Pendaftaran Siswa Baru Bimbingan Belajar Qsc Di Kota Cirebon Metode: Menggunakan algoritma <i>Extreme Gradient Boosting</i> (XGBoost) untuk memprediksi jumlah pendaftar siswa baru Hasil: Model XGBoost dengan konfigurasi terbaik ($n_estimators = 100$, $max_depth = 3$) menghasilkan $R^2 = 0,9779$, RMSE = 6,83, dan MAE = 5,96, yang menunjukkan tingkat akurasi sangat tinggi dalam memprediksi jumlah siswa baru

Gap penelitian ini terletak pada perbedaan domain data dan aspek implementasi sistem. Penelitian terdahulu umumnya berfokus pada prediksi di sektor retail, *e-commerce*, kesehatan, dan ekonomi dengan penekanan pada evaluasi performa model atau perbandingan metode optimasi, tanpa secara spesifik mengkaji prediksi produksi pertanian berbasis variabel iklim. Selain itu, sebagian besar penelitian belum mengintegrasikan model yang telah dioptimasi ke dalam sistem berbasis web sebagai alat pendukung pengambilan keputusan. Dari berbagai penelitian terdahulu, belum banyak penelitian yang menggabungkan optimasi algoritma XGBoost, penggunaan data iklim dan produksi jagung sebagai variabel prediksi, serta implementasi hasil prediksi ke dalam sistem berbasis web dalam satu penelitian yang terintegrasi. Oleh karena itu, penelitian ini berfokus pada penerapan optimasi algoritma XGBoost dalam sistem prediksi produksi jagung berbasis web.



Gambar 1 Mindmap Penelitian

B. Landasan Teori

1. Produksi Jagung

Sektor pertanian memiliki peranan yang sangat penting dalam kehidupan manusia. Namun, tantangan besar seperti pertumbuhan jumlah penduduk yang terus meningkat berdampak pada keterbatasan sumber daya, sehingga memunculkan ancaman dan persaingan terhadap ketahanan pangan[34].

Jagung termasuk komoditas pangan strategis di Indonesia setelah padi. Komoditas ini dimanfaatkan sebagai sumber karbohidrat alternatif, bahan utama pakan ternak, serta sebagai bahan baku dalam industri pangan dan produksi bioenergi[35]. Dengan demikian, tingkat produksi jagung menjadi faktor yang sangat strategis dalam mendukung ketahanan pangan sekaligus meningkatkan kesejahteraan petani, khususnya di daerah agraris seperti Kabupaten Cilacap.

2. Iklim

Iklim termasuk faktor lingkungan yang memegang peranan penting dalam sistem pertanian serta tidak terlepas dari dinamika perubahan iklim yang terus terjadi. Menurut Sahra j, dkk faktor iklim memiliki pengaruh yang signifikan produksi jagung. Nilai koefisien sebesar 0,328 menunjukkan bahwa perubahan kondisi iklim memberikan kontribusi pengaruh terhadap pendapatan petani sebesar 32,8%[36]. Beberapa unsur iklim yang memengaruhi pertumbuhan dan hasil produksi jagung meliputi:

a. Lama penyinaran matahari

Lama penyinaran matahari menjadi salah satu unsur iklim yang memiliki peranan penting dalam pertumbuhan dan produktivitas tanaman jagung. Paparan sinar matahari berhubungan erat dengan proses fotosintesis, yakni mekanisme pembentukan bahan kering tanaman melalui pemanfaatan energi cahaya sebagai sumber utama. Penelitian Szeles A, menunjukan bahwa faktor lingkungan, termasuk ketersediaan radiasi matahari, turut berkontribusi dalam meningkatkan produksi jagung, khususnya pada fase pertumbuhan vegetatif hingga generatif. Studi tersebut menjelaskan bahwa kecukupan intensitas cahaya berpengaruh terhadap efisiensi proses fotosintesis dan secara langsung berdampak pada bobot serta mutu hasil panen[37].

b. Curah hujan

Curah hujan termasuk faktor iklim yang berpengaruh besar terhadap pertumbuhan dan hasil produksi jagung. Ketersediaan air yang diperoleh dari hujan memiliki peranan penting dalam mendukung berbagai proses fisiologis tanaman, seperti fotosintesis, transpirasi, serta penyerapan unsur hara dari dalam tanah. Perubahan pola curah hujan dapat menimbulkan fluktuasi produksi yang tidak stabil dari waktu ke waktu[38][37].

c. Suhu

Suhu termasuk salah satu komponen iklim yang memiliki pengaruh besar terhadap pertumbuhan dan hasil produksi pertanian. Faktor ini terlibat dalam berbagai proses fisiologis tanaman, seperti metabolisme, pembelahan sel, laju fotosintesis, respirasi, hingga perkembangan fenologi tanaman. Penelitian sebelumnya menunjukkan bahwa suhu yang tinggi dapat mempercepat perkembangan siklus hidup organisme serta menghasilkan individu dengan ukuran tubuh yang lebih besar[39].

d. Kelembaban

Kelembaban udara termasuk salah satu unsur iklim yang berpengaruh terhadap pertumbuhan dan produktivitas tanaman jagung. Faktor ini berkaitan erat dengan proses transpirasi, yaitu mekanisme pelepasan uap air melalui stomata daun yang sekaligus berperan dalam pengaturan suhu tanaman. Hubungan antara variabel iklim dan produktivitas tanaman di Indonesia menunjukkan adanya interaksi yang kompleks antara suhu, kelembaban, curah hujan, serta intensitas cahaya terhadap pertumbuhan dan hasil jagung. Meskipun secara statistik pengaruhnya tidak selalu signifikan secara keseluruhan, faktor kelembaban tetap perlu diperhatikan dalam proses interpretasi data klimatologi dan capaian produksi jagung[40].

3. Machine learning

Machine learning (ML) merupakan salah satu cabang dari kecerdasan buatan (*Artificial Intelligence*) yang berfokus pada pengembangan sistem komputer agar mampu mempelajari pola dari data sehingga dapat menghasilkan prediksi atau pengambilan keputusan tanpa harus diprogram secara eksplisit untuk setiap kondisi. *ML* memiliki peran penting dalam mengolah data berukuran besar, kompleks, serta memiliki pola yang beragam yang sulit dianalisis secara manual maupun dengan pendekatan statistik konvensional[34]

Algoritma *machine learning* dalam praktiknya mempelajari hubungan antara variabel masukan (fitur) dan variabel keluaran (target) yang telah diketahui nilainya. Model yang terbentuk selanjutnya dimanfaatkan untuk memprediksi nilai target pada data baru yang sebelumnya belum pernah diproses oleh sistem[41]

Sejumlah penelitian menunjukkan bahwa penerapan *machine learning* telah banyak dilakukan dalam sektor pertanian, khususnya untuk memprediksi hasil panen, termasuk produksi jagung. Sebagai contoh, penelitian mengenai evaluasi model prediksi produktivitas jagung di Indonesia dengan memanfaatkan algoritma ensemble seperti Random Forest, Boosting, dan Bagging menunjukkan bahwa pendekatan *machine learning* dapat menghasilkan model dengan tingkat kesalahan yang relatif rendah serta nilai

R^2 yang tinggi. Hal tersebut mengindikasikan bahwa model mampu merepresentasikan hubungan antara variabel masukan dan keluaran produksi secara efektif[34].

Selain itu, model prediksi produksi pertanian berbasis *machine learning* terbukti mampu melakukan perbandingan antaralgoritma dan menentukan model terbaik berdasarkan metrik evaluasi, seperti RMSE dan R^2 . Penelitian lain juga mengungkapkan bahwa algoritma seperti Random Forest, Support Vector Regression, XGBoost, dan Neural Network dapat menghasilkan prediksi yang akurat terhadap produksi pertanian, terutama ketika memanfaatkan data cuaca, kondisi tanah, serta praktik budidaya sebagai variabel input[7].

4. Extreme Gradient Boosting (XGBoost)

XGBoost (*Extreme Gradient Boosting*) merupakan metode *ensemble learning* berbasis pohon keputusan (*decision tree*) yang dikembangkan menggunakan pendekatan *gradient boosting* dengan tingkat skalabilitas tinggi dan efisiensi komputasi yang optimal[14][30], [32], [33]. Algoritma ini membangun model secara bertahap melalui penambahan pohon keputusan baru yang bertujuan untuk meminimalkan fungsi kerugian (*loss function*) dari model sebelumnya XGBoost tidak hanya mengoptimalkan fungsi objektif, tetapi juga mengendalikan kompleksitas model melalui penerapan teknik regularisasi dan variasi fungsi objektif[31]

Selain berorientasi pada minimisasi kesalahan prediksi, XGBoost juga mengendalikan kompleksitas model melalui penerapan teknik regularisasi pada fungsi objektifnya[42]. Komponen regularisasi tersebut berfungsi untuk menekan risiko overfitting dengan memberikan penalti terhadap jumlah daun pada pohon (number of leaves) serta bobot daun (leaf weights), sehingga model yang dihasilkan menjadi lebih stabil dan robust dibandingkan metode gradient boosting tradisional[43][44].

Berbeda dengan pendekatan *gradient boosting konvensional* yang membangun model secara aditif tanpa dukungan sistem optimasi dan skalabilitas yang memadai, XGBoost dilengkapi berbagai peningkatan teknis, seperti *parallel processing*, *tree pruning*, penanganan otomatis terhadap data hilang (*missing values*), serta optimasi penggunaan memori[14][24]. Integrasi fitur-fitur tersebut memungkinkan XGBoost menghasilkan performa prediksi yang lebih akurat sekaligus meningkatkan efisiensi proses pelatihan, terutama pada dataset dengan karakteristik yang kompleks dan berskala besar.

5. Optimasi

Optimasi adalah proses untuk menemukan solusi paling optimal dari berbagai alternatif yang tersedia berdasarkan suatu fungsi objektif tertentu. Proses ini bertujuan untuk memaksimalkan kinerja atau meminimalkan tingkat kesalahan dalam suatu sistem komputasi maupun model prediksi[45]. Menurut

penelitian Liu X Dkk, berbagai metode optimasi modern, seperti pendekatan berbasis gradient, algoritma pencarian stokastik, serta teknik metaheuristik, dipaparkan secara komprehensif sebagai strategi untuk mengatasi permasalahan berskala besar dan fungsi objektif nonlinier dalam *machine learning*.

Optimasi tidak hanya berfungsi dalam menentukan parameter model, tetapi juga berperan dalam memilih metode evaluasi yang paling tepat serta strategi pembelajaran yang lebih efisien. Sebagai contoh, studi empiris mengenai pengaruh *hyperparameter* tuning terhadap kinerja model menunjukkan bahwa proses penyesuaian parameter dapat memberikan peningkatan performa yang signifikan dibandingkan penggunaan konfigurasi default[46].

6. Hyperparameter Tuning

Hyperparameter tuning merupakan tahapan pengaturan parameter eksternal pada model *machine learning* yang tidak diperoleh secara otomatis dari data, melainkan ditetapkan sebelum proses pelatihan berlangsung. Pada algoritma XGBoost, sejumlah *hyperparameter* utama seperti *learning rate*, *max_depth*, *n_estimators*, *subsample*, dan *colsample_bytree* memiliki peranan penting karena berpengaruh signifikan terhadap performa serta kemampuan generalisasi model[47].

Dalam penelitian ini, proses *hyperparameter* tuning pada model XGBoost dilakukan menggunakan metode *RandomizedSearchCV* dari *Scikit-learn* untuk mendapatkan kombinasi parameter terbaik. Teknik ini dipilih karena mampu mengeksplorasi ruang parameter yang luas dengan efisien dan mengurangi risiko *overfitting* serta meningkatkan akurasi model dibandingkan menggunakan parameter default. Tidak semua parameter XGBoost dituning dalam penelitian ini, fokus tuning hanya pada parameter utama yang secara teori berpengaruh besar terhadap performa model, kompleksitas pohon keputusan, laju pembelajaran, dan generasi model, seperti *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree*. Landasan penggunaan teknik *RandomizedSearchCV* dan pentingnya *hyperparameter* tuning dalam algoritma XGBoost telah dibuktikan dalam beberapa penelitian ilmiah, misalnya studi oleh Nur Alamsyah dkk[22] yang menunjukkan optimasi XGBoost dengan *RandomizedSearchCV* secara signifikan meningkatkan akurasi prediksi kondisi kekeringan hutan dibandingkan model default, serta penelitian optimasi XGBoost menggunakan *Grid Search* dan *Random Search* yang menunjukkan peningkatan performa model setelah tuning parameter utama[20].

7. Kuantil (*Quantile*)

Kuantil (*quantile*) merupakan metode statistik yang digunakan untuk membagi sekumpulan data yang telah diurutkan ke dalam beberapa bagian

berdasarkan proporsi tertentu. Kuantil berfungsi untuk menunjukkan posisi relatif suatu nilai dalam distribusi data sehingga dapat digunakan untuk mengelompokkan data ke dalam kategori tertentu. Salah satu jenis kuantil yang sering digunakan adalah tercil (*tertile*), yaitu pembagian data menjadi tiga kelompok yang sama besar. Pada tercil, data dibagi berdasarkan nilai kuantil 33% (Q1) dan 66% (Q2)[48].

8. Parameter Evaluasi (R^2 , MAE, RMSE)

Dalam pengembangan model prediksi, diperlukan metrik evaluasi untuk menilai kualitas dan akurasi hasil prediksi. Parameter evaluasi berfungsi sebagai tolok ukur sejauh mana model mampu merepresentasikan hubungan antara variabel input dan output, serta seberapa kecil kesalahan prediksi yang dihasilkan. Beberapa parameter evaluasi yang umum digunakan dalam penelitian ini antara lain:

a. Koefisien Determinasi (R^2)

R^2 digunakan untuk mengukur seberapa besar variasi data aktual dapat dijelaskan oleh model[31]. Nilai R^2 berada pada rentang 0 hingga 1. Dirumuskan sebagai:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

b. Mean Absolute error (MAE)

MAE mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi[24]. Semakin kecil nilai MAE, maka semakin baik performa model. Secara matematis dirumuskan sebagai:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

c. Root Mean Squared Error (RMSE)

RMSE mengukur akar dari rata-rata kuadrat selisih antara nilai aktual dan prediksi[33]. RMSE memberikan penalti yang lebih besar terhadap kesalahan yang signifikan. Dirumuskan sebagai:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Dimana:

y_i = nilai aktual

$\hat{y}_i$ = nilai prediksi

$\bar{y}_i$ = rata – rata nilai aktual

n = jumlah data

9. Bahasa Pemrograman *Python*

Python merupakan bahasa pemrograman tingkat tinggi (high-level programming language) yang banyak dimanfaatkan dalam berbagai bidang, seperti pengembangan perangkat lunak, analisis data, dan kecerdasan buatan[49]. Karena sintaksnya yang sederhana dan mudah dipahami, *Python* menjadi salah satu bahasa yang populer dan sering digunakan dalam pengembangan aplikasi maupun sistem berbasis data.


Sejalan dengan hal tersebut, *Python* banyak digunakan dalam penerapan algoritma *machine learning*, termasuk *Extreme Gradient Boosting* (XGBoost), karena kemampuannya mengintegrasikan berbagai pustaka untuk analisis data dan pemodelan secara efektif, efisien, serta mudah dikembangkan. Pada penelitian yang dilakukan oleh Adinagoro R, dkk model prediksi harga mobil bekas dikembangkan menggunakan bahasa pemrograman *Python* dengan memanfaatkan berbagai pustaka seperti *Pandas*, *NumPy*, *Scikit-learn*, dan *XGBoost* dalam proses pelatihan serta evaluasi model. Penggunaan *Python* memungkinkan tahapan prapemrosesan data, rekayasa fitur, optimasi *hyperparameter*, hingga implementasi sistem berbasis web dilakukan secara terpadu dalam satu ekosistem yang terintegrasi[50].

10. Sistem Prediksi Berbasis Web

Sistem prediksi berbasis web merupakan aplikasi prediktif yang mengintegrasikan model prediksi dengan antarmuka web sehingga pengguna dapat mengakses, memasukkan data, dan memperoleh hasil prediksi secara interaktif. Pendekatan ini memanfaatkan teknologi web untuk menyajikan layanan prediksi yang real time, mudah dioperasikan, dan dapat diakses di berbagai perangkat serta lokasi, sehingga meningkatkan kemudahan dan efektivitas dalam pengambilan keputusan berbasis data.

Dalam penelitian-penelitian sebelumnya, sistem prediksi berbasis web telah diterapkan pada berbagai domain dengan model pembelajaran mesin yang dikombinasikan dengan front-end dan back-end aplikasi web untuk menyajikan hasil prediksi kepada pengguna secara langsung[51]. Hal ini menunjukkan bahwa pengembangan sistem prediksi berbasis web tidak hanya relevan secara teoretis tetapi juga praktis dalam mendukung berbagai kebutuhan analitik dan keputusan berbasis data di lingkungan nyata.

11. *Prototyping Method*



Gambar 2 *Prototyping Method*

Prototyping adalah sebuah pendekatan dalam pengembangan perangkat lunak yang bertujuan membuat model awal (prototype) sistem agar pengembang dan pengguna dapat memahami kebutuhan sistem sebelum fase implementasi penuh dilakukan[52][53]. Dalam konteks pengembangan sistem informasi, pendekatan ini membantu memperjelas kebutuhan fungsional dan non-fungsional melalui proses iteratif antara pengembang dan pengguna akhir.

Metode *prototyping* tidak hanya memberikan gambaran awal sistem, tetapi juga berkontribusi pada proses evaluasi pengguna. Dengan *prototipe*, pengguna bisa mengevaluasi antarmuka, alur data, dan fitur yang diusulkan sehingga feedback dapat langsung dimasukkan ke dalam desain berikutnya[52]. Hal ini sejalan dengan temuan dalam penelitian rekayasa perangkat lunak, di mana *prototyping* membantu mengidentifikasi isu usability dan kebutuhan tambahan lebih awal dibandingkan menunggu sampai produk selesai dikembangkan.

12. *Black Box Testing*

Black Box Testing adalah metode pengujian perangkat lunak yang fokus pada pemeriksaan fungsi dan keluaran sistem tanpa mempertimbangkan struktur internal atau kode programnya. Tujuan utama dari metode ini adalah memastikan bahwa setiap fitur sistem bekerja sesuai dengan spesifikasi dan kebutuhan pengguna berdasarkan input yang diberikan dan output yang dihasilkan, tanpa perlu melihat bagaimana sistem itu dibangun secara internal[54]. Dalam konteks pengembangan sistem informasi berbasis web, *Black Box Testing* berperan penting dalam mengevaluasi keandalan dan fungsionalitas antarmuka, alur input-output, serta respon sistem terhadap berbagai skenario penggunaan.

BAB III METODOLOGI

A. Waktu dan Tempat Penelitian

1. Waktu Penelitian

Penelitian ini dimulai dari bulan Maret 2026 sampai dengan bulan Juli 2026.

2. Tempat Penelitian

Penelitian ini dilakukan di BMKG Cilacap dan Dinas Pertanian Cilacap.

B. Alat dan Bahan

Seluruh kebutuhan penelitian disajikan dalam bentuk tabel, sebagaimana ditunjukkan pada Tabel berikut.


Tabel 2 Alat dan Bahan

No	Nama <i>Software</i>	Kegunaan
(1)	(2)	(3)
1	Laptop	Perangkat keras yang digunakan untuk proses pengolahan data, pembangunan model prediksi, serta pengembangan sistem berbasis web
2	Visual Studio Code	Digunakan sebagai <i>code editor</i> dalam proses pengembangan sistem
3	<i>Python</i>	Bahasa pemrograman yang digunakan untuk proses pengolahan data, pembangunan model prediksi, implementasi algoritma XGBoost, dan pengembangan <i>Backend</i> sistem.
4	<i>FastAPI</i>	<i>Framework Backend</i> yang digunakan untuk membangun layanan web (<i>web service</i>) dan menghubungkan model prediksi dengan antarmuka website melalui <i>REST API</i> .
5	Pandas	<i>Library</i> yang digunakan untuk proses pengambilan, pembersihan, transformasi, dan pengolahan data produksi jagung serta data faktor iklim.
6	NumPy	<i>Library</i> yang digunakan untuk komputasi numerik dan pengolahan data dalam bentuk array yang mendukung proses pelatihan model prediksi.
7	Matplotlib	<i>Library</i> yang digunakan untuk membuat visualisasi berupa grafik perbandingan data aktual dan hasil prediksi produksi jagung.

No	Nama <i>Software</i>	Kegunaan
(1)	(2)	(3)
8	<i>Scikit-learn</i>	Digunakan untuk pembagian data latih dan data uji, evaluasi performa model menggunakan metrik pengujian, serta mendukung proses optimasi model.
9	<i>XGBoost Regressor</i>	Algoritma <i>machine learning</i> yang digunakan untuk membangun model prediksi produksi jagung berdasarkan data historis produksi dan faktor iklim.
10	<i>RandomizedSearchCV</i>	Digunakan untuk melakukan optimasi <i>hyperparameter</i> XGBoost guna memperoleh kombinasi parameter terbaik yang menghasilkan performa prediksi optimal.
11	<i>Supabase</i>	Digunakan sebagai database berbasis cloud untuk menyimpan, mengelola, dan menyediakan akses terhadap data yang digunakan oleh sistem website.
12	Browser	Digunakan untuk mengakses, menjalankan, dan menguji fungsionalitas website prediksi produksi jagung yang telah dikembangkan.

C. Prosedur Penelitian

Penelitian ini dilakukan melalui beberapa tahap untuk memastikan hasil akurat dan sesuai dengan tujuan penelitian. Adapun tahapan yang dilakukan ditunjukkan pada Gambar 3.



Gambar 3 Alur Penelitian

1. Studi Literatur

Proses identifikasi masalah dilakukan melalui studi literatur yang relevan sebagai landasan teori, konsep, dan metode penelitian. Kajian difokuskan pada prediksi berbasis *machine learning*, algoritma XGBoost, optimasi *hyperparameter*, serta pengembangan sistem berbasis web sebagai media implementasi model.

Literatur yang dianalisis mencakup penerapan XGBoost pada permasalahan regresi, khususnya di bidang pertanian dan prediksi produksi, serta faktor-faktor yang memengaruhi hasil panen seperti lama penyinaran matahari, curah hujan, suhu, kelembapan, dan indikator iklim lainnya. Hasil kajian menunjukkan bahwa pendekatan konvensional umumnya belum menerapkan optimasi parameter secara sistematis sehingga performa prediksi belum optimal.

Oleh karena itu, optimasi *hyperparameter* menjadi aspek penting untuk meningkatkan kinerja model, dengan parameter utama seperti *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree*. Metode yang banyak digunakan adalah *Random Search* untuk memperoleh kombinasi parameter yang lebih optimal berdasarkan metrik evaluasi MAE, RMSE, dan R^2 .

Selain itu, studi literatur juga mencakup penggunaan bahasa pemrograman *Python* yang didukung berbagai pustaka seperti XGBoost dan *scikit-learn*, serta *framework* web untuk integrasi model ke dalam sistem berbasis web, sehingga hasil prediksi dapat diakses secara lebih efektif dan aplikatif.

2. Identifikasi Kebutuhan

Tahap identifikasi kebutuhan dilakukan untuk menentukan komponen yang diperlukan dalam pembangunan dan optimasi model XGBoost pada prediksi produksi jagung. Kebutuhan yang diidentifikasi meliputi data dan perangkat lunak pendukung proses eksperimen.

Data yang digunakan terdiri dari data iklim (lama penyinaran matahari, curah hujan, suhu, dan kelembapan), data indeks ENSO berupa *Oceanic Niño Index* (ONI), serta data produksi jagung sebagai variabel target dengan periode tahun 2020–2024.

Adapun kebutuhan perangkat lunak yang digunakan meliputi bahasa pemrograman *Python* dengan *Library* *pandas*, *numpy*, XGBoost, serta *scikit-learn* untuk proses optimasi dan evaluasi model, dan *joblib* untuk penyimpanan model. Selain itu, *framework FastAPI* digunakan untuk mengintegrasikan model ke aplikasi berbasis web sebagai sarana implementasi hasil penelitian.

3. Pengumpulan Data

Tahap pengumpulan data dilakukan untuk memperoleh data yang dibutuhkan dalam pembangunan model prediksi produksi jagung. Data yang digunakan dalam penelitian ini terdiri atas data iklim, data indeks iklim global, serta data produksi jagung. Seluruh data dikumpulkan dalam rentang waktu tahun 2020 hingga 2024 agar memiliki periode yang konsisten dan dapat dianalisis secara terintegrasi.

Data iklim yang meliputi lama penyinaran matahari, curah hujan, suhu, dan kelembapan diperoleh dari BMKG Cilacap. Data tersebut digunakan sebagai variabel independen karena faktor-faktor iklim memiliki pengaruh terhadap pertumbuhan dan hasil produksi jagung. Selain itu, data *Oceanic Niño Index* (ONI) diperoleh dari situs resmi <https://ggweather.com/ENSO/ONI.htm> pada halaman ENSO/ONI yang menyediakan informasi terkait fenomena *El Niño* dan *La Niña* yang berpotensi memengaruhi kondisi iklim regional.

Sementara itu, data produksi jagung diperoleh dari Dinas Pertanian Cilacap sebagai variabel dependen dalam penelitian ini. Data produksi yang dikumpulkan mencerminkan jumlah hasil panen jagung pada periode yang sama, yaitu tahun 2020–2024. Seluruh data yang telah diperoleh kemudian disusun dalam format terstruktur dan disesuaikan berdasarkan periode waktu yang sama agar dapat digunakan pada tahap *Pre-Processing* dan pelatihan model XGBoost secara optimal.

4. Pengembangan Model

a. *Pre-Processing*

Tahap *Pre-Processing* data merupakan proses pengolahan awal terhadap data yang telah dikumpulkan sebelum digunakan dalam pembangunan model prediksi. Tahapan ini bertujuan untuk memastikan data berada dalam kondisi yang bersih, terstruktur, dan siap digunakan dalam proses pelatihan model XGBoost. Kualitas *Pre-Processing* sangat berpengaruh terhadap performa dan akurasi model yang dihasilkan.

Pada tahap ini, dilakukan langkah-langkah sebagai berikut:

1) Pembersihan dan Penyelarasan Data

Dilakukan pemeriksaan terhadap kelengkapan data untuk mengidentifikasi adanya missing values atau data yang tidak konsisten. Jika ditemukan data yang kosong, dilakukan penanganan seperti pengisian nilai (imputation) menggunakan metode statistik yang relevan dengan karakteristik data.

```
df = pd.read_excel("data jagung.xlsx")
kolom_fitur = ['LPM (%)', 'CH (mm)', 'ONI', 'Suhu (°C)',
               'Kelembaban (%)']

for col in kolom_fitur:
    df[f'{col}_Lag1'] = df[col].shift(1)
    df[f'{col}_Lag2'] = df[col].shift(2)
    df[f'{col}_Lag3'] = df[col].shift(3)

df_clean = df.dropna().reset_index(drop=True)
```

2) Pembagian Dataset (Data Splitting)

Dataset kemudian dibagi menggunakan metode *random split* dengan rasio 80:20, di mana 80% data dialokasikan sebagai data latih (*training set*) untuk proses pembelajaran model, dan 20% sisanya sebagai data uji (*testing set*) untuk evaluasi performa model.

```
X_train, X_test, y_train, y_test = train_test_split(
    X, y,
    test_size=0.2,
    random_state=42
)
```

3) Transformasi dan Kategorisasi

Data produksi jagung dikonversi dari skala kontinu menjadi data kategorikal (rendah, sedang, tinggi) menggunakan metode kuantil untuk menciptakan distribusi kelas yang seimbang.

```
t_low = df['PRODUKSI'].quantile(0.33)
t_high = df['PRODUKSI'].quantile(0.66)
```

b. Pemodelan (*Baseline & Optimasi*)

1) XGBoost *Baseline*

Pemodelan XGBoost *Baseline* dilakukan sebagai tahap awal dalam proses pembangunan model prediksi produksi jagung. Model *Baseline* digunakan sebagai model pembandingan untuk mengetahui kemampuan dasar algoritma XGBoost sebelum dilakukan proses optimasi *hyperparameter*. Pada tahap ini, model dibangun menggunakan konfigurasi parameter bawaan (*default parameter*) yang telah disediakan oleh algoritma XGBoost tanpa adanya penyesuaian nilai *hyperparameter* tertentu.

Model *Baseline* dilatih menggunakan dataset hasil *preprocessing* yang telah melalui tahapan pembersihan data dan penyesuaian fitur. Data yang digunakan terdiri dari variabel independen berupa faktor iklim yang berperan sebagai fitur masukan, sedangkan produksi jagung digunakan sebagai variabel target yang akan diprediksi. Proses pelatihan dilakukan dengan membagi dataset menjadi data *training* dan data *testing* menggunakan metode *random split* dengan proporsi pembagian data sebesar 80% untuk proses pelatihan dan 20% untuk proses pengujian.

Model XGBoost *Baseline* dibangun menggunakan konfigurasi *hyperparameter* default dari algoritma XGBoost. Parameter yang digunakan meliputi jumlah estimator (*n_estimators*) sebesar 100, kedalaman maksimum pohon (*max_depth*) sebesar 6, tingkat pembelajaran (*learning_rate*) sebesar 0,3, penggunaan sampel data pada setiap pohon (*subsample*) sebesar 1, serta jumlah fitur yang digunakan dalam pembentukan setiap pohon (*colsample_bytree*) sebesar 1. Konfigurasi tersebut digunakan sebagai model awal untuk memperoleh nilai performa dasar sebelum dilakukan proses optimasi *hyperparameter* menggunakan metode *Random Search*.

Implementasi model *Baseline* dilakukan menggunakan bahasa pemrograman *Python* dengan *library* XGBoost. Model dibangun menggunakan kelas *XGBRegressor* dengan parameter bawaan dan *random_state* untuk memastikan hasil pelatihan dapat direproduksi. Proses implementasi model *Baseline* dilakukan dengan kode berikut:

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import os
```

```

from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error

xgb_g = XGBRegressor(
    n_estimators=100,
    learning_rate=0.3,
    max_depth=6,
    subsample=1,
    colsample_bytree=1,
    random_state=42
)

xgb_g.fit(X_train, y_train)
y_all_pred = xgb_g.predict(X)

```

2) Optimasi *Hyperparameter* (*Random Search*)

Tahap optimasi *hyperparameter* bertujuan untuk mendapatkan konfigurasi parameter yang paling tepat pada model XGBoost agar mampu menghasilkan kinerja prediksi yang maksimal. *Hyperparameter* adalah parameter yang ditetapkan sebelum proses pelatihan berlangsung dan tidak diperoleh langsung dari proses pembelajaran data, namun memiliki peranan penting dalam menentukan tingkat akurasi serta kemampuan generalisasi model[17]. Dalam penelitian ini, *hyperparameter* yang dioptimasi meliputi *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree*.

Metode yang diterapkan untuk proses optimasi adalah *Random Search*, yaitu teknik pencarian yang menghasilkan kombinasi *hyperparameter* secara acak berdasarkan rentang nilai yang telah ditentukan sebelumnya. Setiap kombinasi *hyperparameter* yang dihasilkan kemudian dievaluasi menggunakan skema *random split*, yaitu pembagian data secara acak ke dalam data pelatihan dan data pengujian. Pendekatan ini digunakan untuk mengukur performa model pada data yang tidak digunakan selama proses pelatihan sehingga diperoleh konfigurasi *hyperparameter* yang memberikan hasil prediksi terbaik. *Random Search* dipilih karena dinilai lebih efisien dalam menjelajahi ruang parameter dibandingkan metode pencarian menyeluruh seperti *Grid Search*, terutama ketika jumlah kemungkinan kombinasi parameter cukup besar dan kompleks. Dalam implementasinya, rentang parameter dan proses pencarian kombinasi terbaik dilakukan dengan kode berikut

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

```

```

import os


from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split,
RandomizedSearchCV
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error

param_dist = {
    'n_estimators': [50, 100, 200, 300],
    'learning_rate': [0.01, 0.05, 0.1, 0.3],
    'max_depth': [3, 4, 5, 6],
    'subsample': [0.7, 0.8, 0.9, 1.0],
    'colsample_bytree': [0.7, 0.8, 0.9, 1.0]
}

xgb_base = XGBRegressor(random_state=42)
random_search = RandomizedSearchCV(
    estimator=xgb_base, param_distributions=param_dist,
    n_iter=20, cv=3, scoring='r2', n_jobs=-1, random_state=42
)
random_search.fit(X_train, y_train)
model = random_search.best_estimator_

```

Untuk memperjelas tahapan optimasi yang dilakukan, alur proses *Random Search* ditampilkan pada Gambar 4.



Gambar 4 Diagram Alur Optimasi

Berdasarkan Gambar 4, Proses optimasi diawali dengan penggunaan dataset hasil pre-processing yang selanjutnya dibagi menjadi data pelatihan (*training*) sebesar 80% dan data pengujian (*testing*) sebesar 20%. Setelah itu ditentukan rentang nilai *hyperparameter* serta jumlah iterasi yang akan digunakan dalam metode *Random Search*. Pada setiap iterasi, sistem menghasilkan kombinasi *hyperparameter* secara acak untuk membangun model XGBoost. Model yang terbentuk kemudian dievaluasi menggunakan metrik MAE, RMSE, dan R^2 guna mengukur tingkat akurasi prediksi. Hasil evaluasi setiap kombinasi *hyperparameter* disimpan dan proses diulang hingga seluruh iterasi yang telah ditetapkan selesai dijalankan. Selanjutnya, kombinasi *hyperparameter* dengan performa terbaik dipilih sebagai konfigurasi optimal. Model terbaik yang dihasilkan kemudian disimpan dan digunakan pada tahap implementasi sistem prediksi.

Proses optimasi *hyperparameter* pada penelitian ini diimplementasikan menggunakan bahasa pemrograman *Python*. Implementasi ini memungkinkan proses pencarian kombinasi

hyperparameter, pelatihan model, serta evaluasi performa dilakukan secara otomatis, terstruktur, dan efisien.

5. Pengujian Performa Model

a. Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur tingkat kinerja model dalam memprediksi produksi jagung berdasarkan data yang telah diproses. Evaluasi dilakukan terhadap model XGBoost yang telah menggunakan konfigurasi *hyperparameter* optimal hasil *Random Search*. Tujuan evaluasi ini adalah untuk mengetahui tingkat akurasi serta kemampuan model dalam menjelaskan variasi data aktual.

Proses evaluasi dilakukan dengan menghitung nilai beberapa metrik pengukuran, yaitu *Mean Absolute error* (MAE), *Root Mean Squared Error* (RMSE), dan *koefisien determinasi* (R^2). Ketiga metrik tersebut digunakan untuk melihat tingkat kesalahan prediksi serta kemampuan model dalam menyesuaikan hasil prediksi terhadap nilai aktual. Implementasi proses evaluasi model dilakukan menggunakan bahasa pemrograman *Python* dengan kode berikut.

```
r2_all = r2_score(y, y_all_pred)
MAE_all = mean_absolute_error(y, y_all_pred)
RMSE_all = np.sqrt(mean_squared_error(y, y_all_pred))
```

b. Hasil Pengujian Model

Untuk mengetahui tingkat kinerja model dalam memprediksi produksi jagung, dilakukan pengujian performa menggunakan metrik evaluasi MAE, RMSE, dan R^2 . Pengujian dilakukan terhadap model *Baseline* dan model hasil optimasi *hyperparameter* guna melihat perbandingan performa yang dihasilkan. Hasil evaluasi tersebut disajikan pada tabel berikut.

Tabel 3 Hasil Evaluasi Model

Model	MAE	RMSE	R^2
(1)	(2)	(3)	(4)
XGBoost <i>Baseline</i>			
XGBoost Optimasi			

c. Analisis Hasil Pengujian

Hasil pengujian disajikan dalam bentuk tabel evaluasi yang memuat nilai MAE, RMSE, dan R^2 berdasarkan skenario pengujian yang telah dilakukan, sebagaimana ditampilkan pada Tabel 3. Model terbaik dipilih berdasarkan hasil evaluasi tersebut, yaitu model yang memiliki nilai MAE dan RMSE paling rendah serta nilai R^2 paling tinggi. Ketiga parameter tersebut digunakan sebagai indikator untuk menilai tingkat kesalahan prediksi dan kemampuan model dalam menjelaskan variasi data produksi jagung. Berdasarkan hasil pengujian tersebut, model dengan konfigurasi *hyperparameter* terbaik selanjutnya dipilih untuk diimplementasikan ke

dalam sistem berbasis web dan dijadikan dasar dalam penarikan kesimpulan penelitian.

6. Implementasi Website

Tahap implementasi website dilakukan untuk mengintegrasikan model prediksi produksi jagung hasil optimasi *hyperparameter* menggunakan algoritma XGBoost ke dalam sistem berbasis web. Pengembangan sistem dilakukan menggunakan bahasa pemrograman Python dengan *framework FastAPI* sebagai *Backend* yang bertugas menerima data masukan, menjalankan model prediksi, dan menampilkan hasil prediksi kepada pengguna melalui antarmuka website.

Sistem menerima input berupa variabel iklim yang terdiri atas lama penyinaran matahari, curah hujan, suhu udara, kelembapan udara, dan nilai Oceanic Niño Index (ONI). Data tersebut diproses oleh model XGBoost untuk menghasilkan estimasi produksi jagung yang kemudian ditampilkan pada website.

a. *Communication*


Tahap *communication* merupakan tahap awal dalam metode *prototyping* yang bertujuan untuk mengidentifikasi dan memahami kebutuhan pengguna terhadap sistem yang akan dikembangkan. Pada tahap ini dilakukan proses pengumpulan informasi melalui analisis kebutuhan sistem, studi literatur, serta penentuan fitur utama yang harus tersedia dalam aplikasi prediksi produksi. Fokus utama pada tahap ini adalah menentukan alur penggunaan sistem, parameter input yang diperlukan untuk proses prediksi, serta bentuk keluaran yang diharapkan berupa hasil estimasi produksi dan rekomendasi. Hasil dari tahap *communication* menjadi dasar dalam perancangan awal sistem agar pengembangan aplikasi sesuai dengan kebutuhan dan tujuan penelitian.

b. *Quick Design*

Quick design merupakan tahap perancangan awal sistem setelah kebutuhan pengguna teridentifikasi. Pada tahap ini, rancangan aplikasi disusun secara cepat dan iteratif untuk memastikan kesesuaian dengan kebutuhan sebelum masuk ke tahap pembangunan *prototipe*.

Perancangan dilakukan menggunakan *Unified Modeling Language (UML)* untuk memvisualisasikan struktur dan alur sistem, meliputi *use case diagram* untuk mendefinisikan fungsi utama, *activity diagram* untuk menggambarkan alur aktivitas pengguna, serta *sequence diagram* untuk menunjukkan interaksi antar komponen sistem. Hasil tahap ini menjadi dasar dalam pembangunan *prototipe* pada tahap selanjutnya.

1) *Use Case Diagram*




Gambar 5 Use Case Diagram

Use case diagram tersebut menggambarkan interaksi antara aktor Pengguna dan Admin dengan sistem Website Prediksi Produksi Jagung. Pengguna dapat mengakses halaman beranda, halaman prediksi, halaman prediksi jagung, serta melakukan prediksi produksi jagung berdasarkan data yang dimasukkan. Sementara itu, Admin dapat melakukan login, mengakses dashboard admin, mengelola data produksi, serta melakukan prediksi produksi jagung melalui halaman administrasi. Diagram ini menunjukkan fungsi-fungsi utama yang tersedia pada sistem sesuai dengan hak akses masing-masing aktor.

2) *Diagram Activity*

Activity diagram digunakan untuk menggambarkan alur aktivitas yang terjadi pada sistem prediksi produksi jagung berbasis web. Diagram ini terdiri atas dua aktor utama, yaitu User dan Admin, yang masing-masing memiliki alur aktivitas sesuai dengan hak akses dan fungsinya dalam sistem. *Activity diagram* User menggambarkan proses prediksi produksi jagung yang dilakukan oleh pengguna, sedangkan *activity diagram* Admin menggambarkan proses pengelolaan data produksi dan simulasi prediksi pada halaman administrasi.


a) *Activity Diagram User*



Gambar 6 Activity Diagram User

Activity diagram User menggambarkan alur penggunaan sistem oleh pengguna dalam melakukan prediksi produksi jagung. Proses dimulai ketika pengguna mengakses halaman beranda, memilih komoditas yang akan diprediksi, kemudian mengisi data prediksi yang terdiri atas variabel iklim yang diperlukan. Setelah pengguna menekan tombol prediksi, sistem menerima dan melakukan validasi terhadap data yang dimasukkan. Jika data tidak valid, sistem akan menampilkan pesan kesalahan. Sebaliknya, apabila data valid, sistem akan memproses prediksi menggunakan model XGBoost dan menghasilkan estimasi produksi jagung beserta rekomendasi yang kemudian ditampilkan kepada pengguna.

b) *Activity Diagram* Admin



Gambar 7 Activity Diagram Admin

Activity diagram Admin menggambarkan alur aktivitas admin dalam mengelola data produksi dan melakukan simulasi prediksi. Proses diawali dengan login ke dalam sistem menggunakan akun admin. Sistem kemudian melakukan validasi data login. Jika data login tidak valid, sistem akan menampilkan pesan kesalahan. Apabila login berhasil, admin dapat mengakses halaman dashboard dan halaman kelola prediksi.


Pada halaman kelola prediksi, admin dapat melakukan dua aktivitas utama, yaitu menambahkan data produksi dan melakukan simulasi prediksi. Pada proses penambahan data produksi, admin memasukkan data produksi kemudian menyimpannya ke dalam sistem. Selanjutnya, sistem menyimpan data ke *database* dan memperbarui model prediksi berdasarkan data terbaru. Selain itu, admin juga dapat melakukan simulasi prediksi dengan memasukkan data prediksi dan menekan tombol prediksi. Sistem akan melakukan validasi data, memproses prediksi menggunakan model XGBoost, serta menampilkan hasil prediksi dan rekomendasi pada halaman simulasi prediksi.

3) Sequence Diagram

Sequence diagram digunakan untuk menggambarkan interaksi antar objek dalam sistem prediksi produksi jagung berbasis web secara berurutan berdasarkan waktu. Diagram ini terdiri atas dua aktor utama, yaitu User dan Admin, yang masing-masing memiliki alur interaksi dengan sistem sesuai dengan fungsi dan hak aksesnya. *Sequence diagram* User menjelaskan proses pengiriman data dan permintaan prediksi produksi jagung hingga sistem menampilkan hasil prediksi, sedangkan *sequence diagram* Admin menggambarkan proses pengelolaan data produksi, pengaturan data, serta

interaksi admin dalam melakukan simulasi dan pengelolaan hasil prediksi pada sistem.


a) *Sequence Diagram User*



Gambar 8 Sequence Diagram User

Sequence diagram User menggambarkan interaksi antara pengguna, website, *Backend FastAPI*, dan model XGBoost dalam proses prediksi produksi jagung. Proses dimulai ketika pengguna mengakses halaman prediksi dan memasukkan data yang diperlukan, kemudian menekan tombol prediksi. Data yang dimasukkan dikirimkan dari website ke *Backend FastAPI* untuk dilakukan validasi. Jika data tidak valid, sistem akan mengirimkan pesan kesalahan dan menampilkannya kepada pengguna. Namun jika data valid, *Backend* meneruskan data ke model XGBoost untuk dilakukan proses prediksi. Model kemudian menghasilkan nilai prediksi produksi jagung beserta rekomendasi yang dikirim kembali ke *Backend* dan ditampilkan pada halaman website kepada pengguna.

b) *Sequence Diagram Admin*



Gambar 9 Sequence Diagram Admin

Sequence diagram Admin menggambarkan interaksi antara admin, website admin, *Backend FastAPI*, Supabase, dan model XGBoost dalam proses pengelolaan data produksi serta simulasi prediksi. Proses diawali dengan admin melakukan login ke sistem. Data login yang dimasukkan akan divalidasi melalui *Backend*. Jika data login tidak valid, sistem akan menampilkan pesan kesalahan. Sebaliknya, apabila login berhasil, admin dapat mengakses dashboard dan halaman kelola prediksi.

Pada halaman kelola prediksi, admin dapat menambahkan data produksi baru yang kemudian dikirim ke *Backend* untuk disimpan ke dalam *database* Supabase. Setelah data berhasil disimpan, sistem melakukan pembaruan model prediksi menggunakan data terbaru. Selain itu, admin juga dapat melakukan simulasi prediksi dengan memasukkan data prediksi melalui halaman kelola prediksi. Data yang dimasukkan akan divalidasi terlebih dahulu oleh sistem. Jika data valid, *Backend* meneruskan data ke model XGBoost untuk menghasilkan prediksi produksi jagung dan rekomendasi.

Hasil prediksi tersebut kemudian dikirim kembali ke website dan ditampilkan pada halaman simulasi prediksi admin.

c. *Prototyping Construction*

Tahap *prototyping construction* merupakan proses pembangunan rancangan sistem yang telah dibuat pada tahap *quick design* menjadi bentuk *prototipe* yang dapat dijalankan. Pada tahap ini, desain antarmuka dan struktur sistem mulai diimplementasikan menggunakan teknologi yang telah ditentukan. Fitur utama sistem, seperti pengelolaan data produksi, input data prediksi, proses prediksi menggunakan model XGBoost, serta tampilan hasil prediksi mulai direalisasikan dalam bentuk fungsional sehingga dapat diuji dan dievaluasi.

Website dikembangkan menggunakan pendekatan *monolithic architecture*, di mana seluruh komponen sistem dibangun dalam satu aplikasi yang terintegrasi. Pada implementasinya, bagian *Frontend* dikembangkan menggunakan HTML, CSS, JavaScript, dan template engine Jinja2 untuk menampilkan antarmuka pengguna. Bagian *Backend* dikembangkan menggunakan *framework FastAPI* yang bertugas mengelola logika sistem, proses prediksi, serta komunikasi dengan basis data. Adapun penyimpanan data dilakukan menggunakan Supabase yang digunakan untuk mengelola data produksi, data pengguna, serta metadata model prediksi.

Prototipe yang dihasilkan berfungsi sebagai representasi awal sistem yang telah mengintegrasikan antarmuka pengguna, layanan *Backend*, basis data, dan model prediksi ke dalam satu kesatuan aplikasi. Melalui prototipe ini, fungsi-fungsi utama sistem dapat dijalankan dan dievaluasi sebelum digunakan sebagai sistem akhir pada penelitian.

d. *Costumer Review and Evaluation*

Pada tahap ini, pengguna melakukan peninjauan dan evaluasi terhadap *prototipe* awal yang telah dikembangkan untuk memastikan kesesuaiannya dengan hasil komunikasi sebelumnya. Apabila masih terdapat ketidaksesuaian atau kebutuhan penambahan fitur, maka proses akan kembali ke tahap komunikasi untuk dilakukan perbaikan. Namun, apabila *prototipe* telah sesuai dengan kebutuhan, maka pengembangan dapat dilanjutkan ke tahap berikutnya.

7. Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa seluruh fitur pada sistem prediksi produksi jagung berbasis web telah berjalan sesuai dengan kebutuhan dan spesifikasi yang telah ditetapkan. Metode pengujian yang digunakan dalam penelitian ini adalah *Black Box Testing*, yang berfokus pada pengujian fungsi sistem berdasarkan input dan output tanpa melihat struktur kode program. Pengujian ini bertujuan untuk memvalidasi setiap fitur utama, seperti proses input data, perhitungan prediksi, serta tampilan hasil pada antarmuka pengguna. Setiap skenario pengujian dirancang berdasarkan kebutuhan fungsional sistem untuk memastikan bahwa sistem dapat memberikan respons yang sesuai

terhadap berbagai kondisi penggunaan. Adapun skenario pengujian yang dilakukan disajikan pada Tabel berikut.

a. Skenario Pengujian User

Tabel 4 Skenario Pengujian User

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Akses beranda	Mengakses halaman website	Menampilkan halaman beranda	[] Berhasil [] Tidak Berhasil
Akses menu prediksi	Klik menu “Prediksi”	Menampilkan pilihan komoditas prediksi	[] Berhasil [] Tidak Berhasil
Akses prediksi Jagung	Klik komoditas “Jagung”	Menampilkan halaman prediksi Jagung	[] Berhasil [] Tidak Berhasil
Input tahun tanam	Mengisi kolom tahun prediksi	Data tahun dapat diinput	[] Berhasil [] Tidak Berhasil
Input bulan tanam	Mengisi kolom bulan tanam	Data bulan dapat diinput	[] Berhasil [] Tidak Berhasil
Input variabel iklim	Mengisi lama penyinaran, curah hujan, indeks ENSO, suhu udara, kelembaban	Data variabel iklim dapat diinput	[] Berhasil [] Tidak Berhasil
Validasi input tidak lengkap	Klik tombol “Hitung Prediksi” tanpa melengkapi data	Sistem menampilkan pesan eror	[] Berhasil [] Tidak Berhasil
Proses prediksi	Klik tombol “Hitung Prediksi” dengan data lengkap	Sistem memproses data dan menampilkan hasil prediksi	[] Berhasil [] Tidak Berhasil
Tampilan hasil prediksi	Setelah prediksi berhasil	Sistem menampilkan estimasi bulan panen dan prediksi panen dalam ton	[] Berhasil [] Tidak Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Tampilan kategori prediksi	Setelah prediksi berhasil	Sistem menampilkan keterangan sesuai kategori produksi (rendah, sedang, atau tinggi)	[] Berhasil [] Tidak Berhasil
Tampilan rekomendasi	Setelah prediksi berhasil	Sistem menampilkan hasil prediksi dan rekomendasi	[] Berhasil [] Tidak Berhasil

b. Skenario Pengujian Admin

Tabel 5 Skenario Pengujian Admin


Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Login Admin	Masuk ke halaman login admin	Menampilkan halaman login admin	[] Berhasil [] Tidak Berhasil
Input <i>username</i>	Mengisi kolom <i>username</i>	<i>Username</i> dapat diinput	[] Berhasil [] Tidak Berhasil
Input password	Mengisi kolom password	<i>Password</i> dapat diinput	[] Berhasil [] Tidak Berhasil
Validasi salah inputan	Klik tombol “Masuk ke Dashbord” dengan data yang salah	Sistem menampilkan pesan eror	[] Berhasil [] Tidak Berhasil
Akses dashboard admin	Setelah login berhasil	Menampilkan dashboard admin	[] Berhasil [] Tidak Berhasil
Akses kelola prediksi	Klik menu “Kelola Prediksi”	Menampilkan halaman kelola prediksi	[] Berhasil [] Tidak Berhasil
Akses kelola prediksi Jagung	Klik pilihan kelola prediksi Jagung	Menampilkan halaman kelola prediksi Jagung	[] Berhasil [] Tidak Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Akses kelola dataset	Klik pilihan “Kelola Dataset”	Menampilkan halaman kelola dataset	[] Berhasil [] Tidak Berhasil
Input data baru	Mengisi kolom tahun, bulan, prediksi, variabel iklim, dan produksi Jagung	Data tahun, bulan, prediksi, variabel iklim, dan produksi Jagung dapat diinputkan	[] Berhasil [] Tidak Berhasil
Konfirmasi simpan data baru	Klik button “Simpan ke Dataset”	Sistem menampilkan konfirmasi	[] Berhasil [] Tidak Berhasil
Simpan dataset baru	Klik button “Simpan”	Data tersimpan di <i>database</i> dan riwayat dataset terdaftar	[] Berhasil [] Tidak Berhasil
Akses Edit data	Pilih salah satu data lalu klik tombol edit	Menampilkan data yang akan diedit	[] Berhasil [] Tidak Berhasil
Melakukan edit data	Mengganti data yang ada dengan data baru	Data dapat diubah ke data baru	[] Berhasil [] Tidak Berhasil
Konfirmasi edit data	Klik button “Simpan Perubahan”	Sistem menampilkan konfirmasi	[] Berhasil [] Tidak Berhasil
Simpan data	Klik button “Simpan”	Data tersimpan di <i>database</i> dan riwayat dataset terdaftar	[] Berhasil [] Tidak Berhasil
Akses hapus data	Pilih salah satu data lalu klik tombol edit	Sistem menampilkan konfirmasi	[] Berhasil [] Tidak Berhasil
Konfirmasi edit data	Klik “Hapus Data”	Data terhapus dari <i>database</i> dan riwayat dataset terdaftar	[] Berhasil [] Tidak Berhasil
Akses simulasi prediksi	Klik menu “Simulasi Prediksi”	Menampilkan halaman simulasi prediksi	[] Berhasil [] Tidak Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Input tahun tanam	Mengisi kolom tahun prediksi	Data tahun dapat diinput	☐ Berhasil ☐ Tidak Berhasil
Input bulan tanam	Mengisi kolom bulan tanam	Data bulan dapat diinput	☐ Berhasil ☐ Tidak Berhasil
Input variabel iklim	Mengisi lama penyinaran, curah hujan, indeks ENSO, suhu udara, kelembaban	Data variabel iklim dapat diinput	☐ Berhasil ☐ Tidak Berhasil
Validasi input tidak lengkap	Klik tombol “Hitung Prediksi” tanpa melengkapi data	Sistem menampilkan pesan eror	☐ Berhasil ☐ Tidak Berhasil
Proses prediksi	Klik tombol “Hitung Prediksi” dengan data lengkap	Sistem memproses data dan menampilkan hasil prediksi	☐ Berhasil ☐ Tidak Berhasil
Tampilan hasil prediksi	Setelah prediksi berhasil	Sistem menampilkan estimasi bulan panen dan prediksi panen dalam ton	☐ Berhasil ☐ Tidak Berhasil
Tampilan kategori prediksi	Setelah prediksi berhasil	Sistem menampilkan keterangan sesuai kategori produksi (rendah, sedang, atau tinggi)	☐ Berhasil ☐ Tidak Berhasil
Tampilan rekomendasi	Setelah prediksi berhasil	Sistem menampilkan hasil prediksi dan rekomendasi	☐ Berhasil ☐ Tidak Berhasil

D. Jadwal Penelitian

Jadwal penelitian dibuat untuk mengatur waktu agar penelitian terarah dan terstruktur, jadwal penelitian dibuat dalam bentuk *Gantt Chart* berikut *Gantt Chart* jadwal penelitian dapat dilihat pada Gambar 11.



Gambar 10 Gantt Chart Jadwal Penelitian

BAB IV HASIL DAN PEMBAHASAN

A. Hasil

1. Pengumpulan Data

Pada tahap ini data yang dikumpulkan bersumber dari BMKG Cilacap yang mencakup beberapa data lama penyinaran matahari, curah hujan, suhu, kelembaban per bulan, dan data indeks ENSO yang bersumber dari website GGWeather (*ONI Index*). Serta data produksi jagung yang bersumber dari Dinas Pertanian Cilacap per bulan.

a. Spesifikasi Data

Beberapa kriteria data yang bisa dimuat sebagai berikut:

Tabel 6 Spesifikasi Data

No	Nama Variabel	Deskripsi	Sumber Data
(1)	(2)	(3)	(4)
1	Lama Penyinaran Matahari (LPM)	Rata-rata LPM selama 1 bulan	BMKG Cilacap
2	Curah Hujan	Jumlah curah hujan selama 1 bulan	BMKG Cilacap
3	Suhu	Rata-rata suhu selama 1 bulan	BMKG Cilacap
4	Kelembaban	Rata-rata kelembaban selama 1 bulan	BMKG Cilacap
5	Indeks ENSO	Kondisi fenomena ENSO	Website GGWeather ONI
6	Produksi Jagung	Data dependen yang digunakan untuk target prediksi	Dinas Pertanian Cilacap

Tabel 7 Contoh Data yang diambil

Tahun	Bulan	LPM (%)	Curah Hujan (mm)	Suhu (°C)	Kelembaban (%)	ONI	P (ton)
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
2020	Januari	59	159,0	28,1	83	0,5	290,77
2020	Februari	59	342,5	27,9	83	0,48	21422,02

Tahun	Bulan	LPM (%)	Curah Hujan (mm)	Suhu (°C)	Kelembaban (%)	ONI	P (ton)
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
2020	Maret	63	519,0	27,9	84	0,4	14977,83
2020	April	74	274,0	28,1	84	0,19	1271,26
2020	Mei	66	380,4	28,2	84	- 0,08	840,67
....							
2024	Desember	40	464	27,9	84	- 0,53	141


b. Alasan memilih data

Pemilihan variabel dalam penelitian ini didasarkan pada faktor-faktor iklim yang secara teoritis berpengaruh terhadap pertumbuhan dan produktivitas tanaman jagung. Tanaman jagung merupakan komoditas pertanian yang sangat dipengaruhi oleh kondisi lingkungan selama proses pertumbuhan, sehingga perubahan unsur-unsur iklim dapat berdampak pada hasil produksi yang diperoleh.

- 1) Lama penyinaran matahari dipilih karena berperan dalam proses fotosintesis tanaman. Intensitas dan durasi penyinaran yang memadai dapat mendukung pembentukan biomassa dan perkembangan tanaman secara optimal.
- 2) Curah hujan dipilih karena berkaitan dengan ketersediaan air yang dibutuhkan tanaman selama masa pertumbuhan. Kekurangan maupun kelebihan curah hujan dapat memengaruhi produktivitas tanaman jagung.
- 3) Suhu dipilih karena berpengaruh terhadap berbagai proses fisiologis tanaman, seperti perkecambahan, pertumbuhan vegetatif, dan pembentukan biji.
- 4) Kelembaban dipertimbangkan karena dapat memengaruhi laju evapotranspirasi serta kondisi lingkungan yang mendukung pertumbuhan tanaman.
- 5) *Oceanic Niño Index* (ONI) digunakan untuk merepresentasikan fenomena ENSO (*El Niño Southern Oscillation*) yang diketahui dapat memengaruhi pola curah hujan dan kondisi iklim di Indonesia, sehingga berpotensi memberikan dampak terhadap produksi pertanian, termasuk jagung.

Selain didasarkan pada kajian teoritis dan penelitian terdahulu, pemilihan variabel juga didukung melalui analisis korelasi Spearman untuk mengetahui hubungan antara masing-masing variabel independen terhadap

variabel dependen, yaitu produksi jagung. Hasil analisis korelasi ditunjukkan pada gambar 12.




Gambar 11 Matriks Korelasi

Berdasarkan analisis korelasi Spearman, nilai korelasi antara variabel iklim dan produksi jagung tergolong rendah, yaitu lama penyinaran matahari dan curah hujan sebesar -0,01, ONI sebesar -0,11, suhu sebesar 0,05, serta kelembaban sebesar -0,13. Meskipun demikian, variabel-variabel tersebut tetap digunakan karena memiliki dasar teoritis terhadap pertumbuhan jagung dan berpotensi membentuk hubungan nonlinier. Selain itu, setiap variabel ditransformasikan menjadi fitur *lag* hingga tiga periode sebelumnya agar model dapat menangkap pengaruh kondisi iklim pada beberapa bulan sebelumnya terhadap produksi jagung.

2. Proses Pemodelan Data

Proses pemodelan data dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan algoritma *Extreme Gradient Boosting* (XGBoost) untuk membangun model prediksi produksi jagung. Pada penelitian ini, pemodelan dilakukan dalam dua skenario, yaitu XGBoost *Baseline* dan XGBoost dengan optimasi *hyperparameter* menggunakan metode *Random Search*. Model *Baseline* digunakan sebagai acuan awal untuk mengetahui performa dasar algoritma XGBoost, sedangkan model optimasi digunakan untuk memperoleh kombinasi *hyperparameter* terbaik guna meningkatkan akurasi prediksi. Kedua model melalui tahapan persiapan data, pembentukan fitur lag, penentuan variabel input dan target, pembagian data training dan testing, pembangunan model, evaluasi, serta visualisasi hasil prediksi. Berikut penjelasan tahapan prosesnya:

a. Pemodelan XGBoost *Baseline*




Gambar 12 Grafik Prediksi Produksi Jagung *Baseline*

Berdasarkan Gambar Grafik Prediksi Produksi Jagung menggunakan model XGBoost *Baseline*, terlihat bahwa hasil prediksi (garis merah) memiliki pola yang mengikuti data aktual (garis biru) pada periode Januari 2020 hingga Desember 2024. Model mampu menangkap pola perubahan produksi jagung, meskipun masih terdapat beberapa perbedaan antara nilai prediksi dan nilai aktual terutama pada periode dengan perubahan produksi yang cukup tinggi.

Hasil evaluasi model *Baseline* menunjukkan nilai R^2 sebesar 0,887, MAE sebesar 772,09 ton, dan RMSE sebesar 1927,52 ton. Nilai tersebut menunjukkan bahwa model XGBoost *Baseline* mampu menjelaskan sebagian besar variasi data produksi jagung dengan tingkat kesalahan prediksi yang masih terdapat pada beberapa periode tertentu. Hasil ini kemudian digunakan sebagai acuan sebelum dilakukan proses optimasi *hyperparameter* menggunakan metode *Random Search* untuk meningkatkan performa model.

b. Pemodelan XGBoost dengan Optimasi *Random Search*



Gambar 13 Grafik Optimasi Prediksi Produksi Jagung

Berdasarkan Gambar Grafik Prediksi Produksi Jagung menggunakan model XGBoost hasil optimasi *Random Search*, terlihat bahwa hasil prediksi (garis merah) memiliki pola yang lebih mendekati data aktual (garis biru) pada periode Januari 2020 hingga Desember 2024. Model hasil optimasi mampu mengikuti pola perubahan produksi jagung dengan lebih baik dibandingkan model *Baseline*, terutama pada beberapa periode dengan perubahan produksi yang cukup signifikan.

Hasil evaluasi model setelah dilakukan optimasi *hyperparameter* menunjukkan peningkatan performa dengan nilai R^2 sebesar 0,893, MAE sebesar 748,08 ton, dan RMSE sebesar 1876,00 ton. Peningkatan nilai R^2 serta penurunan nilai MAE dan RMSE menunjukkan bahwa proses optimasi *hyperparameter* berhasil meningkatkan kemampuan model dalam mempelajari pola hubungan antara faktor iklim dan produksi jagung.

3. Hasil Evaluasi Model

Hasil evaluasi kinerja model ditampilkan dalam bentuk tabel yang berisi nilai MAE, RMSE, dan R^2 . Pengujian dilakukan pada dua skenario, yaitu model XGBoost *Baseline* dan model XGBoost dengan optimasi *hyperparameter* menggunakan *Random Search*. Perbandingan ini bertujuan untuk mengetahui peningkatan performa yang dihasilkan setelah proses optimasi dilakukan.

Model	MAE (Ton)	RMSE (Ton)	R^2
(1)	(2)	(3)	(4)
XGBoost <i>Baseline</i>	772,09	1927,52	0,887
XGBoost Optimasi	748,08	1876,00	0,893

4. Analisis Hasil Evaluasi

Berdasarkan hasil evaluasi kinerja model yang ditunjukkan pada tabel, dapat diketahui bahwa model XGBoost dengan optimasi *hyperparameter*

menggunakan *Random Search* memiliki performa yang lebih baik dibandingkan model *XGBoost Baseline*. Evaluasi dilakukan menggunakan tiga metrik utama, yaitu *Mean Absolute error* (MAE), *Root Mean Square Error* (RMSE), dan *R² Score*.

Pada model *XGBoost Baseline*, diperoleh nilai MAE sebesar 772,09 ton, RMSE sebesar 1927,52 ton, dan *R²* sebesar 0,887. Nilai ini menunjukkan bahwa model sudah cukup baik dalam mempelajari pola data, namun tingkat kesalahan prediksi masih relatif tinggi.

Setelah dilakukan optimasi *hyperparameter* menggunakan *Random Search*, terjadi peningkatan performa model. Nilai MAE menurun menjadi 748,08 ton, RMSE menurun menjadi 1876,00 ton, dan *R²* meningkat menjadi 0,893. Penurunan MAE sebesar 24,01 ton atau sekitar 3,11% menunjukkan bahwa rata-rata kesalahan prediksi model menjadi lebih kecil dibandingkan model *Baseline*. Sementara itu, RMSE juga mengalami penurunan sebesar 51,52 ton atau sekitar 2,67%, yang mengindikasikan berkurangnya error besar dalam prediksi model.

Selain itu, nilai *R²* mengalami peningkatan dari 0,887 menjadi 0,893, yang menunjukkan bahwa kemampuan model dalam menjelaskan variasi data produksi jagung menjadi lebih baik setelah proses optimasi dilakukan. Peningkatan ini mengindikasikan bahwa model hasil optimasi memiliki kemampuan yang lebih optimal dalam menangkap pola hubungan antara variabel input dan output.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa penerapan *Random Search* dalam optimasi *hyperparameter* berhasil meningkatkan kinerja model *XGBoost*, baik dari sisi akurasi prediksi maupun kemampuan model dalam merepresentasikan data.


5. Implementasi Website

Pada tahap implementasi sistem, dilakukan proses pengintegrasian model prediksi produksi jagung ke dalam aplikasi berbasis web. Implementasi ini bertujuan untuk merealisasikan hasil pemodelan yang telah dilakukan sebelumnya agar dapat digunakan secara langsung oleh pengguna melalui antarmuka sistem. Tahap ini mencakup perancangan arsitektur sistem, implementasi model prediksi, serta pengembangan *Backend* dan *Frontend* yang saling terhubung dalam satu kesatuan sistem.

a. Arsitektur Sistem

Arsitektur sistem prediksi produksi jagung dirancang menggunakan pendekatan *monolithic architecture* yang terdiri atas tiga lapisan utama, yaitu *Frontend*, *Backend*, dan *database*. Arsitektur ini bertujuan untuk mengintegrasikan model *XGBoost* ke dalam aplikasi berbasis web sehingga

proses prediksi dapat dilakukan secara otomatis melalui antarmuka yang dapat diakses oleh pengguna. Arsitektur website yang digunakan pada penelitian ini ditunjukkan pada Gambar 14.



Gambar 14 Arsitektur Sistem Prediksi

Berdasarkan Gambar 14, sistem prediksi produksi jagung dikembangkan menggunakan pendekatan *monolithic architecture* yang terdiri atas tiga komponen utama, yaitu *Frontend*, *Backend*, dan *database* yang saling terintegrasi dalam satu kesatuan aplikasi. Pada arsitektur ini, seluruh proses pengelolaan data, pemanggilan model *machine learning*, serta penyajian informasi kepada pengguna dikelola melalui satu aplikasi *Backend* sehingga proses komunikasi antar komponen dapat berlangsung secara lebih sederhana dan efisien.

1) *Frontend*

Frontend merupakan lapisan antarmuka yang berfungsi sebagai media interaksi antara pengguna dengan sistem. *Frontend* dikembangkan menggunakan HTML, CSS, *JavaScript*, dan *Jinja2 Template Engine* yang diintegrasikan dengan *framework FastAPI*. Penggunaan HTML digunakan untuk membangun struktur halaman website, CSS digunakan untuk mengatur tampilan dan desain antarmuka agar lebih menarik serta responsif, sedangkan *JavaScript* digunakan untuk mendukung interaktivitas halaman. Adapun *Jinja2* digunakan untuk menampilkan data dinamis yang dikirimkan oleh *Backend* ke halaman website.

Melalui *Frontend*, pengguna dapat mengakses berbagai halaman yang tersedia, seperti halaman beranda, halaman prediksi, dan halaman hasil prediksi. Pada halaman prediksi, pengguna dapat memasukkan data variabel iklim yang terdiri atas lama penyinaran matahari, curah hujan,

suhu udara, kelembapan udara, serta nilai *Oceanic Niño Index* (ONI). Data yang dimasukkan pengguna kemudian dikirimkan ke *Backend* melalui HTTP Request untuk diproses lebih lanjut. Selain itu, *Frontend* juga berfungsi menampilkan hasil prediksi produksi jagung, kategori produksi, dan rekomendasi yang dihasilkan oleh sistem.

2) *Backend*

Backend merupakan komponen utama yang mengelola seluruh logika bisnis sistem dan dikembangkan menggunakan *framework FastAPI* berbasis bahasa pemrograman Python. *Backend* berperan sebagai penghubung antara *Frontend*, *database* Supabase, dan model *machine learning* yang digunakan untuk melakukan prediksi produksi jagung.

Ketika pengguna mengirimkan data melalui halaman prediksi, *Backend* akan menerima permintaan (*request*) yang dikirimkan dari *Frontend*. Selanjutnya sistem melakukan validasi terhadap data masukan untuk memastikan bahwa seluruh parameter yang diperlukan telah terisi dan memiliki format yang sesuai. Setelah proses validasi berhasil dilakukan, *Backend* akan memproses data tersebut dan meneruskannya ke model XGBoost yang telah disimpan dalam format file *pickle* (.pkl).

Selain menangani proses prediksi, *Backend* juga bertanggung jawab dalam melakukan pengelolaan data pada sistem, seperti mengambil data dari *database* Supabase, menyimpan data produksi baru yang ditambahkan oleh admin, mencatat aktivitas pengguna, serta mengelola proses pelatihan ulang model apabila terdapat pembaruan data. *Backend* juga melakukan pemanggilan model prediksi menggunakan fungsi `load_model_bundle()` yang bertugas memuat model hasil pelatihan beserta informasi pendukung lainnya, seperti fitur yang digunakan dan parameter model.

Setelah model menghasilkan nilai prediksi produksi jagung, *Backend* mengolah hasil tersebut untuk menentukan kategori produksi dan rekomendasi yang sesuai. Hasil akhir kemudian dikirim kembali ke *Frontend* dalam bentuk HTTP Response untuk ditampilkan kepada pengguna melalui halaman website.

3) *Database*

Tabel 8 Struktur *Database*

No	Nama Kolom	Tipe Data	Keterangan
(1)	(2)	(3)	(4)
1	tahun	number	Tahun Produksi
2	bulan	text	Bulan Produksi
3	lpm	varchar	Lama penyinaran matahari (%)
4	ch	varchar	Curah hujan (mm)
5	oni	varchar	Oceanic Niño Index

No	Nama Kolom	Tipe Data	Keterangan
(1)	(2)	(3)	(4)
6	suhu	varchar	Suhu udara (°C)
7	kelembaban	varchar	Kelembaban udara (%)
8	produksi	varchar	Produksi jagung (ton)

Tabel 7 menunjukkan struktur *database* yang digunakan pada sistem prediksi produksi jagung. *Database* menggunakan Supabase sebagai media penyimpanan data yang berfungsi untuk menyimpan, mengelola, dan menyediakan data yang dibutuhkan dalam proses pelatihan model maupun operasional sistem. Data disimpan pada tabel data_jagung yang terdiri atas atribut tahun, bulan, lama penyinaran matahari (lpm), curah hujan (ch), *Oceanic Niño Index* (oni), suhu udara (suhu), kelembaban udara (kelembaban), dan produksi jagung (produksi).


Variabel lama penyinaran matahari, curah hujan, suhu udara, kelembaban udara, dan nilai ONI digunakan sebagai variabel independen yang menjadi masukan bagi model prediksi, sedangkan variabel produksi digunakan sebagai variabel dependen atau target prediksi. Data yang tersimpan pada tabel data_jagung dimanfaatkan oleh *Backend* untuk proses pelatihan model XGBoost, pembentukan fitur lag, evaluasi model, serta proses prediksi produksi jagung yang dilakukan melalui website.

b. Implementasi Antarmuka Pengguna

Implementasi antarmuka pengguna (*user interface*) merupakan tahap penerapan hasil perancangan sistem ke dalam bentuk halaman website yang dapat diakses dan digunakan oleh pengguna. Antarmuka dikembangkan sebagai media komunikasi antara pengguna dengan sistem sehingga seluruh fungsi yang tersedia dapat dioperasikan dengan mudah. Pada penelitian ini, implementasi antarmuka meliputi beberapa halaman utama yang mendukung proses prediksi produksi jagung, yaitu halaman utama dan halaman prediksi. Tampilan masing-masing halaman dijelaskan sebagai berikut.

1) Halaman Utama


Halaman beranda merupakan halaman utama yang pertama kali ditampilkan ketika pengguna mengakses website prediksi produksi jagung. Halaman ini berfungsi sebagai media penyampaian informasi mengenai sistem, tujuan pengembangan website, serta fitur yang tersedia bagi pengguna.




Gambar 15 Halaman Utama

2) Halaman Prediksi

Halaman prediksi menampilkan hasil prediksi produksi jagung berdasarkan data iklim dan nilai ONI dalam satuan ton, disertai kategori produksi dan rekomendasi pendukung. Implementasi halaman prediksi ditunjukkan pada Gambar 16, 17, 18, 19.



Gambar 16 Halaman Prediksi Jagung



Gambar 17 Halaman Prediksi Jagung (Grafik Perbandingan)

Prediksi Pertanian Beranda Informasi Kontak Prediksi

Masukkan Variabel untuk Prediksi

Silakan inputkan nilai variabel berikut secara berurutan ke bawah.

Tahun Tanam: 2026
Tahun waktu tanam jagung.

Bulan Tanam: Juni
Bulan waktu tanam jagung.

LPM (Penyinaran): 80.0 %
Lama penyinaran matahari rata-rata dalam sebulan.

Curah Hujan: 120.0 mm
Jumlah total curah hujan dalam sebulan.

Suhu Udara: 28.0 °C
Rata-rata suhu udara dalam sebulan.

Hasil Estimasi Produksi

Estimasi Produksi Bulan September

3062.7 Ton

Kategori Hasil

Sedang

Produksi diperkirakan sedang dibandingkan kondisi normal.

Kategori Produksi

- Rendah: 33% dari rata-rata
- Sedang: 33% - 66%
- Tinggi: > 66% dari rata-rata

*Berdasarkan data historis Kabupaten Cilacap

Gambar 18 Halaman Prediksi Jagung (Hasil Prediksi)

Prediksi Pertanian Beranda Informasi Kontak Prediksi

Hitung Prediksi

Rekomendasi Masa Tanam

- ✓ Kondisi tanaman jagung saat ini cukup baik. Pertahankan pola irigasi dan perawatan agar produktivitas tetap stabil.
- ✓ Produktivitas diprediksi berada pada kategori sedang. Pemupukan susulan secara rutin dapat membantu meningkatkan hasil panen jagung.
- ✓ Lakukan monitoring kelembaban tanah secara berkala untuk menjaga kondisi pertumbuhan tanaman tetap optimal, terutama pada musim kemarau.
- ✓ Pembersihan gulma di sekitar lahan disarankan agar unsur hara dan nutrisi tanaman tidak terbagi dengan tanaman liar.

Prediksi Pertanian Hubungi Kami Navigasi Ikuti Kami


Gambar 19 Halaman Prediksi Jagung (Hasil Rekomendasi)

c. Implementasi Antarmuka Admin

Implementasi antarmuka admin (*admin interface*) merupakan tahap penerapan hasil perancangan sistem ke dalam bentuk halaman website yang digunakan admin untuk mengelola data dan menjalankan fungsi sistem. Antarmuka admin pada penelitian ini terdiri atas halaman login, dashboard, dan kelola prediksi yang mencakup penambahan data produksi serta simulasi prediksi produksi jagung. Tampilan masing-masing halaman dijelaskan sebagai berikut

1) Halaman Login Admin


Halaman login admin digunakan sebagai sarana autentikasi untuk membatasi akses ke fitur administrasi sistem. Pada halaman ini, admin memasukkan alamat email dan kata sandi yang terdaftar untuk dapat mengakses dashboard dan fitur pengelolaan data.



Gambar 20 Halaman Login Admin

2) Halaman Dashboard Admin

Halaman dashboard admin merupakan halaman utama yang ditampilkan setelah proses login berhasil dilakukan. Halaman ini menyediakan informasi umum mengenai sistem serta akses menuju fitur pengelolaan data produksi dan simulasi prediksi.



Gambar 21 Halaman Dashboard Admin

3) Halaman Kelola Prediksi

Halaman kelola prediksi digunakan oleh admin untuk mengelola data yang digunakan dalam proses prediksi serta melakukan simulasi prediksi produksi jagung. Halaman ini terdiri atas fitur pengelolaan dataset produksi dan simulasi prediksi.



Gambar 22 Halaman Kelola Prediksi


a) Halaman Kelola Dataset Produksi

Halaman kelola dataset produksi digunakan untuk mengelola data produksi jagung dan data pendukung lainnya yang tersimpan pada *database*. Admin dapat menambahkan, mengubah, dan menghapus data yang digunakan sebagai sumber data dalam proses pelatihan model prediksi.

Gambar 23 Halaman Kelola Dataset Produksi

b) Halaman Simulasi Prediksi

Halaman simulasi prediksi digunakan untuk melakukan pengujian prediksi produksi jagung berdasarkan data variabel iklim dan nilai ONI yang dimasukkan oleh admin. Hasil prediksi yang dihasilkan model XGBoost akan ditampilkan pada halaman yang sama.



Gambar 24 Halaman Simulasi Prediksi

6. Pengujian Sistem

Pengujian sistem dilakukan untuk mengetahui tingkat kesesuaian fungsi dari sistem prediksi produksi jagung berbasis web yang telah dikembangkan. Pengujian dilakukan terhadap fitur utama yang tersedia pada sistem, baik fitur pengguna maupun fitur admin, untuk memastikan setiap fungsi dapat berjalan sesuai dengan hasil yang diharapkan.

Hasil pengujian sistem menggunakan metode *Black Box Testing* disajikan pada Lampiran 1. Berdasarkan hasil pengujian tersebut, seluruh fungsi yang diuji dapat berjalan sesuai dengan skenario yang telah ditentukan sehingga sistem dapat dinyatakan telah memenuhi kebutuhan fungsional yang telah dirancang.

B. Pembahasan

Hasil penelitian yang telah diperoleh menunjukkan bahwa penerapan optimasi *hyperparameter* menggunakan metode *Random Search* mampu meningkatkan performa algoritma XGBoost dalam memprediksi produksi jagung. Selain menghasilkan model dengan tingkat akurasi yang lebih baik, penelitian ini juga berhasil mengimplementasikan model prediksi ke dalam sistem berbasis web sehingga dapat digunakan secara praktis oleh pengguna. Pembahasan pada bagian ini difokuskan pada analisis faktor-faktor yang memengaruhi pembentukan model, peningkatan performa yang diperoleh setelah proses optimasi, serta implementasi model ke dalam sistem.

Data yang digunakan dalam penelitian terdiri atas variabel lama penyinaran matahari, curah hujan, suhu udara, kelembaban udara, *Oceanic Niño Index* (ONI), dan produksi jagung sebagai variabel target. Pemilihan variabel tersebut didasarkan pada teori dan penelitian terdahulu yang menyatakan bahwa faktor iklim memiliki pengaruh terhadap pertumbuhan dan produktivitas tanaman jagung[36]. Ketersediaan cahaya matahari berperan dalam proses fotosintesis, curah hujan berkaitan dengan ketersediaan air, suhu memengaruhi proses fisiologis tanaman,

sedangkan kelembaban dan fenomena ENSO dapat memengaruhi kondisi lingkungan pertanian secara keseluruhan.

Berdasarkan hasil analisis korelasi Spearman yang dilakukan pada tahap pengolahan data, diperoleh nilai korelasi yang relatif rendah antara masing-masing variabel iklim terhadap produksi jagung. Nilai korelasi lama penyinaran matahari dan curah hujan sebesar -0,01, suhu sebesar 0,05, ONI sebesar -0,11, serta kelembaban sebesar -0,13 menunjukkan bahwa hubungan antarvariabel tidak bersifat kuat secara langsung. Namun demikian, kondisi tersebut tidak menunjukkan bahwa variabel iklim tidak memiliki pengaruh terhadap produksi jagung. Hubungan antara faktor iklim dan hasil pertanian umumnya bersifat kompleks, dipengaruhi oleh berbagai faktor, serta memiliki pola hubungan yang tidak selalu linear. Oleh karena itu, algoritma XGBoost digunakan karena memiliki kemampuan dalam mempelajari hubungan kompleks dan nonlinier.

Selain penggunaan variabel iklim, penelitian ini juga menerapkan pembentukan fitur lag pada variabel independen. Pembentukan fitur lag bertujuan untuk menangkap pengaruh kondisi iklim pada periode sebelumnya terhadap produksi jagung pada periode saat ini. Dengan adanya fitur lag satu bulan, dua bulan, dan tiga bulan sebelumnya, model memperoleh informasi historis yang lebih lengkap sehingga mampu mempelajari pola temporal pada data.

Setelah proses pembentukan fitur selesai dilakukan, dataset dibagi menjadi data pelatihan dan data pengujian menggunakan metode train-test split dengan proporsi 80:20. Pembagian data dilakukan tanpa proses pengacakan untuk mempertahankan urutan waktu pada data produksi jagung yang bersifat runtun waktu. Data pelatihan digunakan untuk proses pembentukan model dan optimasi *hyperparameter*, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model terhadap data yang belum dipelajari sebelumnya.

Pada tahap optimasi *hyperparameter*, metode *Random Search* diterapkan untuk mencari kombinasi parameter terbaik. Proses pencarian dilakukan dengan menguji sebanyak 20 kombinasi *hyperparameter* yang dipilih secara acak dari ruang parameter yang telah ditentukan. Setiap kombinasi parameter dievaluasi menggunakan 3-fold cross validation pada data pelatihan dengan menggunakan nilai R^2 sebagai dasar pemilihan model terbaik. Parameter yang dioptimasi meliputi *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree*. Parameter tersebut berpengaruh terhadap kompleksitas model, kemampuan pembelajaran, serta kemampuan generalisasi model terhadap data baru.

Hasil optimasi menunjukkan adanya peningkatan performa model berdasarkan nilai evaluasi yang diperoleh. Nilai MAE berhasil diturunkan dari 772,09 ton menjadi 748,08 ton, sedangkan nilai RMSE mengalami penurunan dari 1927,52 ton menjadi 1876,00 ton. Selain itu, nilai R^2 meningkat dari 0,887 menjadi 0,893.

Penurunan MAE menunjukkan bahwa rata-rata kesalahan prediksi model hasil optimasi lebih kecil dibandingkan model *Baseline*. Sementara itu, penurunan RMSE menunjukkan bahwa kesalahan prediksi dengan nilai besar juga mengalami pengurangan. Peningkatan nilai R^2 menunjukkan bahwa model hasil optimasi memiliki kemampuan lebih baik dalam menjelaskan variasi produksi jagung.

Apabila dihitung berdasarkan persentase perubahan performa, optimasi *hyperparameter* mampu menurunkan nilai MAE sebesar 3,11% dan menurunkan nilai RMSE sebesar 2,67%. Selain itu, nilai R^2 meningkat dari 0,887 menjadi 0,893. Hasil tersebut menunjukkan bahwa kombinasi *hyperparameter* yang diperoleh melalui *Random Search* memberikan pengaruh positif terhadap kemampuan model dalam menghasilkan prediksi produksi jagung yang lebih baik dibandingkan model dengan parameter awal.

Selain evaluasi menggunakan MAE, RMSE, dan R^2 , dilakukan pengujian statistik untuk mengetahui apakah terdapat perbedaan performa antara model XGBoost *Baseline* dan XGBoost Optimasi. Pengujian statistik dilakukan terhadap nilai *absolute error* hasil prediksi kedua model pada data yang sama sehingga menghasilkan data berpasangan. Tahapan pengujian statistik diawali dengan uji normalitas untuk menentukan metode uji perbedaan yang digunakan.

Tabel 9 Hasil Uji Normalitas *Shapiro-Wilk*

Variabel	Statistik <i>Shapiro-Wilk</i>	Sig.
(1)	(2)	(3)
Selisih AE <i>Baseline</i> dan Optimasi	0,760	<0,001

Berdasarkan hasil uji normalitas menggunakan metode *Shapiro-Wilk* pada Tabel 8, diperoleh nilai signifikansi sebesar <0,001. Nilai tersebut lebih kecil dari 0,05 sehingga dapat disimpulkan bahwa data selisih error antara model XGBoost *Baseline* dan XGBoost Optimasi tidak berdistribusi normal. Oleh karena itu, pengujian dilanjutkan menggunakan metode non-parametrik *Wilcoxon Signed-Rank Test*.

Tabel 10 Hasil Uji *Wilcoxon Signed-Rank Test*

Statistik	Nilai
(1)	(2)
Negative Ranks	9
Postitive Ranks	48
Ties	0
Total	57
Z	-3,023
Asymp. Sig. (2-tailed)	0,003

Berdasarkan hasil pengujian menggunakan *Wilcoxon Signed-Rank Test* pada Tabel 9, diperoleh 48 positive ranks yang menunjukkan bahwa pada nilai *absolute*

error model XGBoost Optimasi lebih tinggi dibandingkan model XGBoost Baseline. Sementara itu, terdapat 9 *negative ranks* yang menunjukkan kondisi sebaliknya. Selain itu, tidak ditemukan data dengan nilai yang sama (*ties* = 0), sehingga seluruh pasangan data memiliki perbedaan nilai *absolute error*. Hasil uji Wilcoxon menunjukkan nilai Z sebesar -3,023 dengan nilai Asymp. Sig. (2-tailed) sebesar 0,003. Nilai signifikansi tersebut lebih kecil dari 0,05, sehingga dapat disimpulkan bahwa terdapat perbedaan yang signifikan secara statistik antara performa model XGBoost Baseline dan XGBoost Optimasi berdasarkan nilai *absolute error*.

Meskipun hasil *Wilcoxon Signed-Rank Test* menunjukkan bahwa pada sebagian besar pasangan data model XGBoost Optimasi memiliki nilai *absolute error* yang lebih tinggi dibandingkan model Baseline, hasil evaluasi MAE dan RMSE menunjukkan bahwa model hasil optimasi tetap memiliki rata-rata kesalahan prediksi yang lebih rendah. Hal ini disebabkan oleh adanya beberapa nilai *absolute error* yang sangat besar pada model Baseline sehingga meningkatkan rata-rata kesalahan prediksinya.

Selain ditinjau dari nilai evaluasi dan pengujian statistik, peningkatan performa model juga dapat diamati melalui visualisasi hasil prediksi. Grafik perbandingan antara data aktual dan hasil prediksi menunjukkan bahwa model hasil optimasi mampu mengikuti pola perubahan produksi jagung dengan lebih baik dibandingkan model *Baseline*.

Setelah diperoleh model dengan performa terbaik, tahap selanjutnya adalah implementasi model ke dalam sistem berbasis web. Implementasi dilakukan menggunakan framework *FastAPI* yang berfungsi sebagai *backend* sistem. Pemanfaatan *FastAPI* memungkinkan proses integrasi model machine learning dengan website dilakukan secara efisien karena framework ini mendukung komunikasi data yang cepat antara *frontend* dan *backend*. Selain itu, *FastAPI* juga memudahkan proses pengelolaan permintaan pengguna dan pemanggilan model prediksi yang telah disimpan sebelumnya.

Model hasil optimasi disimpan dalam format file *pickle* (.pkl) menggunakan library *Joblib*. Penyimpanan model dalam format tersebut memungkinkan model digunakan kembali tanpa perlu melakukan proses pelatihan ulang setiap kali sistem dijalankan. Ketika pengguna melakukan prediksi melalui website, *backend* akan memuat model yang telah tersimpan, menerima data masukan dari pengguna, melakukan validasi data, kemudian meneruskan data tersebut ke model XGBoost untuk menghasilkan prediksi produksi jagung. Hasil prediksi yang diperoleh selanjutnya dikirim kembali ke *frontend* dan ditampilkan kepada pengguna dalam bentuk informasi produksi serta kategori hasil prediksi.

Implementasi sistem tidak hanya berfokus pada fitur prediksi, tetapi juga mencakup pengelolaan data melalui halaman admin. Admin dapat menambahkan data produksi baru yang selanjutnya disimpan ke dalam *database* Supabase. Data yang tersimpan tersebut dapat digunakan sebagai sumber data untuk proses pelatihan ulang model sehingga sistem memiliki kemampuan untuk menyesuaikan model berdasarkan data terbaru yang tersedia. Dengan demikian, sistem yang dikembangkan tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai sarana pengelolaan data produksi secara terintegrasi.

Berdasarkan hasil pengujian menggunakan metode *Black Box Testing*, seluruh fungsi yang terdapat pada sistem berhasil berjalan sesuai dengan kebutuhan yang telah dirancang. Pengujian dilakukan terhadap fitur akses halaman beranda, halaman prediksi, input data prediksi, proses prediksi, tampilan hasil prediksi, login admin, dashboard admin, pengelolaan data produksi, serta simulasi prediksi pada halaman admin. Seluruh skenario pengujian memperoleh status valid yang menunjukkan bahwa sistem mampu memberikan keluaran sesuai dengan hasil yang diharapkan.

Keberhasilan pengujian tersebut menunjukkan bahwa integrasi antara model XGBoost, *backend FastAPI*, *database* Supabase, dan antarmuka website telah berjalan dengan baik. Pengguna dapat melakukan prediksi produksi jagung secara langsung melalui website, sedangkan admin dapat mengelola data dan melakukan simulasi prediksi sesuai kebutuhan. Kondisi ini menunjukkan bahwa sistem yang dikembangkan telah memenuhi tujuan implementasi penelitian, yaitu menyediakan sarana prediksi produksi jagung yang dapat digunakan secara praktis melalui platform berbasis web.

Secara keseluruhan, hasil penelitian menunjukkan bahwa optimasi *hyperparameter* menggunakan *Random Search* berhasil meningkatkan kinerja model XGBoost dalam memprediksi produksi jagung. Selain itu, model yang telah dioptimasi juga berhasil diimplementasikan ke dalam sistem berbasis web dan mampu menjalankan seluruh fungsi yang dirancang dengan baik. Dengan nilai R^2 sebesar 0,893 serta keberhasilan implementasi dan pengujian sistem, penelitian ini menunjukkan bahwa kombinasi algoritma XGBoost, optimasi *hyperparameter*, dan teknologi web dapat menjadi solusi yang efektif dalam mendukung proses prediksi produksi jagung dan membantu pengambilan keputusan pada sektor pertanian.

BAB V KESIMPULAN

A. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa optimasi *hyperparameter* menggunakan metode *Random Search* mampu meningkatkan kinerja model XGBoost dalam memprediksi produksi jagung. Model sebelum optimasi (Baseline) menghasilkan nilai MAE sebesar 772,09 ton, RMSE sebesar 1927,52 ton, dan R^2 sebesar 0,887. Setelah dilakukan optimasi *hyperparameter*, performa model meningkat dengan nilai MAE sebesar 748,08 ton, RMSE sebesar 1876,00 ton, dan R^2 sebesar 0,893. Hasil tersebut menunjukkan bahwa optimasi *hyperparameter* mampu meningkatkan akurasi model melalui penurunan nilai MAE sebesar 3,11%, penurunan nilai RMSE sebesar 2,67%, serta peningkatan nilai R^2 dari 0,887 menjadi 0,893. Selain itu, berdasarkan hasil uji statistik *Wilcoxon Signed-Rank Test*, diperoleh nilai Asymp. Sig. (2-tailed) sebesar 0,003 ($p < 0,05$), sehingga dapat disimpulkan bahwa terdapat perbedaan yang signifikan secara statistik antara nilai absolute error model XGBoost Baseline dan XGBoost Optimasi. Dengan demikian, optimasi *hyperparameter* menggunakan metode *Random Search* terbukti mampu meningkatkan performa model XGBoost dalam memprediksi produksi jagung berdasarkan hasil evaluasi metrik kinerja dan pengujian statistik yang telah dilakukan.

Model XGBoost yang telah dioptimasi berhasil diintegrasikan ke dalam sistem prediksi produksi jagung berbasis web menggunakan *FastAPI* sebagai backend dan Supabase sebagai database. Sistem yang dikembangkan mampu melakukan prediksi produksi jagung berdasarkan data masukan pengguna serta mendukung pengelolaan data produksi, data pengguna, dan informasi hasil prediksi melalui halaman admin. Selain itu, sistem juga mampu menampilkan hasil prediksi beserta informasi evaluasi model sehingga memudahkan pengguna dalam memperoleh informasi prediksi secara cepat dan terstruktur. Berdasarkan hasil pengujian menggunakan metode *Black Box Testing*, seluruh fitur pada sistem berfungsi sesuai dengan kebutuhan yang telah dirancang dan memperoleh hasil valid. Dengan demikian, implementasi model XGBoost yang telah dioptimasi ke dalam sistem berbasis web dapat digunakan sebagai alat bantu dalam melakukan prediksi produksi jagung serta mendukung proses perencanaan dan pengambilan keputusan di bidang pertanian.

B. Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya.

1. Dapat menggunakan jumlah data yang lebih banyak dan rentang waktu yang lebih panjang serta menambahkan faktor lain yang berpotensi memengaruhi produksi jagung, seperti luas panen, penggunaan pupuk, atau faktor ekonomi pertanian sehingga diharapkan dapat meningkatkan akurasi prediksi.
2. Penelitian selanjutnya diharapkan dapat membandingkan performa XGBoost dengan algoritma machine learning lainnya untuk memperoleh metode prediksi yang paling optimal.
3. Sistem dapat dikembangkan lebih lanjut dengan penambahan fitur visualisasi data yang lebih interaktif serta implementasi data pipeline untuk otomatisasi pembaruan data sehingga proses pengelolaan data menjadi lebih efisien dan minim kesalahan input.
4. Dapat mempertimbangkan penerapan model berbasis time series atau pendekatan hybrid untuk menangkap pola temporal data produksi secara lebih optimal.

DAFTAR PUSTAKA

- [1] R. Yogautami, C. Dewi, Azoya Gea, and G. Eska, “Analisis peramalan (forecasting) produksi jagung di provinsi lampung dengan aplikasi pom qm,” no. Vol. 7 No. 4 (2023), Nov. 2023, doi: 10.21776/ub.jepa.2023.007.04.9.
- [2] H. R. Stie, J. Bulan, G. P. Stie, and R. A. Stie, “Analisis pengaruh faktor produksi terhadap kesejahteraan petani melalui produksi jagung di kampung naena muktupura kabupaten mimika,” *JEBI: Jurnal Ekonomi dan Bisnis*, vol. 3, no. 3, Mar. 2025.
- [3] L. R. E. Malau, K. R. Rambe, N. A. Ulya, and A. G. Purba, “Dampak perubahan iklim terhadap produksi tanaman pangan di indonesia,” *Jurnal Penelitian Pertanian Terapan*, vol. 23, no. 1, pp. 34–46, Mar. 2023, doi: 10.25181/jppt.v23i1.2418.
- [4] B. Nurwenda, Saediman, and Yusria, “Analisis dampak perubahan iklim terhadap ketahanan pangan petani jagung lokal di kecamatan kabawo kabupaten muna,” *Journal Of Social Science Research*, no. Vol. 4 No. 4 (2024), Aug. 2024, doi: 10.31004/innovative.v4i4.14016.
- [5] S. J. Sutanto, S. B. Zarzoza Mora, I. Supit, and M. Wang, “Compound and cascading droughts and heatwaves decrease maize yields by nearly half in Sinaloa, Mexico,” *npj Natural Hazards*, vol. 1, no. 1, Oct. 2024, doi: 10.1038/s44304-024-00026-7.
- [6] A. K. Kassa *et al.*, “Integrating climate data and remote sensing for maize and wheat yield modelling in ethiopia’s key agricultural region,” *Remote Sens. (Basel)*, vol. 17, no. 3, Feb. 2025, doi: 10.3390/rs17030491.
- [7] Z. Wirda and A. Ramadhani, “Model prediksi produksi pertanian berbasis machine learning dan data lapangan,” *SISFO: Jurnal Ilmiah Sistem Informasi*, vol. 9, no. 2, 2025, doi: 10.29103/.v9i2.26015.
- [8] S. Wang *et al.*, “Integrating meteorological and breeding data to predict maize yields using machine learning algorithms,” *Front. Plant Sci.*, vol. 16, 2025, doi: 10.3389/fpls.2025.1722068.
- [9] M. A. Kaium *et al.*, “Modeling impacts of climate-induced yield variability and adaptations on wheat and maize in a sub-tropical monsoon climate - using fuzzy logic,” *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-09820-3.
- [10] A. Hura, “Penerapan machine learning untuk prediksi produktivitas pertanian berbasis data cuaca di indonesia,” *Ilmu Teknologi Informasi*

Indonesia, no. Vol. 2, No. 1 (2026), Jan. 2026, doi: 10.70134/jitifna.v2i1.1018.

- [11] B. Emir *et al.*, “Xgboost outperforms other machine learning models in diagnosing sepsis-associated thrombocytopenia: a multicenter retrospective study,” *Front. Med. (Lausanne)*, vol. 13, Feb. 2026, doi: 10.3389/fmed.2026.1715551.
- [12] G. A. Syafarina, M. Amin, and Z. Zaenuddin, “Perbandingan tree-based ensemble (random forest, xgboost, lightgbm) dan deep learning untuk prediksi klik iklan online,” *Technologia : Jurnal Ilmiah*, vol. 17, no. 1, p. 257, Jan. 2026, doi: 10.31602/tji.v17i1.21627.
- [13] F. Pratama, E. Ali, Rahmaddeni, and W. Agustin, “Perbandingan kinerja xgboost dan lightgbm dalam klasifikasi depresi pada mahasiswa berdasarkan faktor demografi dan akademik,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 53–64, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2439.
- [14] N. Setiawan and H. Zakaria, “Implementasi bayesian optimization untuk meningkatkan akurasi prediksi penjualan menggunakan algoritma xgboost (studi kasus: cv xyz),” Jan. 2026. doi: 10.47324/ilkominfo.v9i1.410.
- [15] A. N. Sahin Demirel, “Investigating the impact of climate variables on the organic honey yield in turkey using XGBoost machine learning,” *J. Sci. Food Agric.*, vol. 105, no. 1, pp. 84–92, Jan. 2025, doi: 10.1002/jsfa.13806.
- [16] B. M. Lionel, R. Musabe, O. Gatera, and C. Twizere, “A comparative study of machine learning models in predicting crop yield,” *Discover Agriculture*, vol. 3, no. 1, Sep. 2025, doi: 10.1007/s44279-025-00335-z.
- [17] A. B. Hikmah, “Optimasi hyperparameter ensemble learning untuk prediksi penyakit liver berdasarkan data pasien,” 2025. doi: 10.47970/siskom-kb.v8i3.798.
- [18] M. Zlobin and V. Bazylevych, “Bayesian optimization for tuning hyperparametrs of machine learning models: a performance analysis in xgboost,” *Computer systems and information technologies*, no. 1, pp. 141–146, Mar. 2025, doi: 10.31891/csit-2025-1-16.
- [19] M. Tayebi and S. El Kafhali, “A novel approach based on xgboost classifier and bayesian optimization for credit card fraud detection,” *Cyber Security and Applications*, vol. 3, Dec. 2025, doi: 10.1016/j.csa.2025.100093.
- [20] A. E. Firdaus, J. Manurung, H. Saragih, and A. M. Prabukusumo, “Optimization of XGBoost hyperparameters using grid search and random search for credit card default prediction,” no. Vol. 14 No. 2 (2025), Oct. 2025, doi: 10.35335/mandiri.v14i2.468.

- [21] H. Utama and D. J. Santoso, "Pemodelan prediktif konsumsi energi listrik di pabrik baja berbasis xgboost untuk pengelolaan sumber daya berkelanjutan," no. Vol. 2 No. 3 (2025), Aug. 2025, doi: 10.59095/jmb.v2i3.234.
- [22] N. Alamsyah, B. Budiman, T. P. Yoga, and R. Y. R. Alamsyah, "Xgboost hyperparameter optimization using randomizedsearchcv for accurate forest fire drought condition prediction," *Jurnal Pilar Nusa Mandiri*, vol. 20, no. 2, pp. 103–110, Sep. 2024, doi: 10.33480/pilar.v20i2.5569.
- [23] S. F. Aqilah Khansa, N. Ulinnuha, and W. D. Utami, "Grid search and random search hyperparameter tuning optimization in xgboost algorithm for parkinson's disease classification," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 19, no. 3, pp. 1609–1624, Jul. 2025, doi: 10.30598/barekengvol19iss3pp1609-1624.
- [24] H. Wijaya, D. Pramana Hostiadi, and E. Triandini, "Meningkatkan prediksi penjualan retail xyz dengan teknik optimasi random search pada model xgboost," *SPINTER*, vol. 1, no. 2, p. 2024, 2024.
- [25] A. Haris, M. Sholeh, L. Muflikhah, and N. Yudistira, "Peningkatan akurasi prediksi harga barang impor menggunakan xgboost dan particle swarm optimization," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 2, pp. 351–358, Apr. 2025, doi: 10.25126/jtiik.2025129419.
- [26] A. S. Tiastama and I. Budi, "Comparison between random search and genetic algorithm in xgboost hyperparameter tuning for retail sales forecasting," no. Vol. 13 No. 4 (2024), Aug. 2024, doi: 10.33022/ijcs.v13i4.4285.
- [27] D. Tribuana, B. Baharuddin, and A. Muhammad Resky, "Penerapan algoritma xgboost untuk prediksi kepuasan pelanggan pada layanan e-commerce: studi pada dataset transaksi nyata," *Jurnal Teknologi dan Bisnis Cerdas*, vol. 1, no. 1, pp. 50–59, Jul. 2025, doi: 10.64476/jtbc.v1i1.5.
- [28] Z. Wirda and A. Ramadhani, "Model prediksi produksi pertanian berbasis machine learning dan data lapangan," *SISFO: Jurnal Ilmiah Sistem Informasi*, vol. 9, no. 2, 2025, doi: 10.29103/.v9i2.26015.
- [29] H. Li, J. Gao, Y. Guo, and X. G. Yuan, "Application of XGBoost model and multi-source data for winter wheat yield prediction in Henan Province of China," *Big Data and Information Analytics*, vol. 9, no. 0, pp. 29–47, 2025, doi: 10.3934/bdia.2025002.
- [30] P. Marchanda Izzati and F. Fitriyani, "Implementasi algoritma xgboost untuk prediksi capaian bulanan pendapatan daerah kota bandung," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 2, pp. 104–111, Aug. 2025, doi: 10.37859/coscitech.v6i2.9578.

- [31] M. Safii, I. Okta Kirana, S. Aiko Leana, and Y. Indahwati Gultom, “Model prediksi penjadwalan produksi energi terbarukan dengan algoritma xgboost dan analisis interpretatif menggunakan shap,” Jul. 2025, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsi>
- [32] A. Pangestu and S. Mujiyono, “Implementasi algoritma xgboost untuk prediksi status gizi balita berbasis website,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 176–187, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2390.
- [33] F. H. Syahadah, R. T. Subagio, and P. Rizqiyah, “Penerapan xgboost dalam prediksi pendaftaran siswa baru bimbingan belajar qsc di kota cirebon,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 3S1, Oct. 2025, doi: 10.23960/jitet.v13i3S1.7998.
- [34] F. Murni Hamundu, G. Arviana Rahman, A. Tenriawaru, R. Armin, P. Studi Ilmu Komputer, and U. Halu Oleo, “Evaluasi model prediksi produktivitas jagung di indonesia menggunakan algoritma pembelajaran mesin,” vol. 10, no. 1, 2025.
- [35] O. Erenstein, M. Jaleta, K. Sonder, K. Mottaleb, and B. M. Prasanna, “Global maize production, consumption and trade: trends and R&D implications,” Oct. 01, 2022, *Springer Science and Business Media B.V.* doi: 10.1007/s12571-022-01288-7.
- [36] J. F. Sahra, U. Untari, and N. Nurliah, “Analisis faktor-faktor yang mempengaruhi pendapatan petani jagung manis di kampung semangga jaya, distrik semangga,” *AGRICOLA*, vol. 14, no. 2, pp. 81–88, Nov. 2024, doi: 10.35724/ag.v14i2.6355.
- [37] A. Széles, É. Horváth, K. Simon, P. Zagyi, and L. Huzsvai, “Maize production under drought stress: nutrient supply, yield prediction,” *Plants*, vol. 12, no. 18, Sep. 2023, doi: 10.3390/plants12183301.
- [38] E. K. Nassary and A. J. Magubika, “Spatiotemporal trends in maize production and seasonal variability in tanzania,” *Discover Agriculture*, vol. 3, no. 1, Sep. 2025, doi: 10.1007/s44279-025-00260-1.
- [39] R. G. Simanjuntak and N. Farida, “Respons populasi sitophilus oryzae terhadap variasi suhu pada media beras: studi awal untuk perlindungan hasil pertanian,” *Jurnal Hama dan Penyakit Tumbuhan*, vol. 13, no. 3, pp. 150–158, Sep. 2025, doi: 10.21776/ub.jurnalhpt.2025.013.3.3.
- [40] S. Syaranamual and Y. Muyan, “Correlation between climate data and yields of some prominent food crops in manokwari, west papua, indonesia,” *Agromet*, vol. 38, no. 1, pp. 58–67, Jun. 2024, doi: 10.29244/j.agromet.38.1.58-67.

- [41] M. Z. Naser, “A review of machine learning with small and limited data,” *J. Big Data*, Jan. 2026, doi: 10.1186/s40537-025-01346-9.
- [42] A. Dwi Azahra and K. Monika Dian Pertiwi, “Deteksi serangan dos pada iot berbasis mqtt menggunakan xgb dan pso,” *Jurnal Algoritma*, vol. 22, no. 2, Dec. 2025, doi: 10.33364/algoritma/v.22-2.2623.
- [43] F. Pratama, E. Ali, Rahmadden, and W. Agustin, “Perbandingan kinerja xgboost dan lightgbm dalam klasifikasi depresi pada mahasiswa berdasarkan faktor demografi dan akademik,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 53–64, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2439.
- [44] Moh. Erkamim, A. M. Tanniewa, I. AP, and N. Nurhayati, “Analisis perbandingan metode adaboost, gradient boosting, dan xgboost untuk kalsifikasi status gizi pada balita,” *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1799–1807, Dec. 2024, doi: 10.47065/bits.v6i3.5717.
- [45] X. Liu, H. Qi, S. Jia, Y. Guo, and Y. Liu, “Recent advances in optimization methods for machine learning: a systematic review,” Jul. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/math13132210.
- [46] Dr. V. Yuvaraj, “An empirical study on the impact of hyperparameter tuning on model performance,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 13, no. 10, pp. 1084–1089, Oct. 2025, doi: 10.22214/ijraset.2025.74685.
- [47] R. Abyasa and E. Nurmawati, “Prediksi volume ekspor udang menggunakan indeks google trend dan faktor berpengaruh lainnya dengan machine learning,” *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 12, no. 3, p. 500, Jul. 2024, doi: 10.26418/justin.v12i3.78900.
- [48] Muhammad Najiy Yullah, “Analisis spasial kasus persebaran tuberkolosis kabupaten dan kota di provinsi jawa barat tahun 2022-2024,” *Router : Jurnal Teknik Informatika dan Terapan*, vol. 3, no. 4, pp. 106–119, Dec. 2025, doi: 10.62951/router.v3i4.748.
- [49] Adawiyah Ritonga and Yahfizham Yahfizham, “Studi literatur perbandingan bahasa pemrograman c++ dan bahasa pemrograman python pada algoritma pemrograman,” *Jurnal Teknik Informatika dan Teknologi Informasi*, vol. 3, no. 3, pp. 56–63, Nov. 2023, doi: 10.55606/jutiti.v3i3.2863.
- [50] R. E. Adinagoro, I. Dwi, R. Premana, R. B. Pamungkas, P. Aryasetya, and D. Joedhistiro, “Pengembangan sistem prediksi harga mobil bekas di pasar india menggunakan algoritma xgboost dan nlp,” no. Prosiding Seminar

Nasional Teknologi Informasi dan Bisnis (SENATIB) 2025, p. 2025, Jul. 2025, doi: 10.47701/w6511j19.




- [51] A. Nur Rais, “Sistem informasi prediksi risiko kredit keuangan berbasis web machine learning,” Dec. 2024. doi: 10.31294/justika.v4i2.7509.
- [52] A. Syukron, E. Saputro, and P. Widodo, “Penerapan metode prototype pada perancangan sistem informasi koperasi simpan pinjam berbasis website,” *CONTEN: Computer and Network Technology*, vol. 3, no. 1, pp. 21–28, 2023, [Online]. Available: <http://jurnal.bsi.ac.id/index.php/conten>
- [53] R. M. R. Fauzan and C. Mukmin, “Sistem informasi pendaftaran online pada lembaga bahasa universitas muhammadiyah palembang berbasis web,” *Jurnal Digital Teknologi Informasi*, vol. 6, no. 1, p. 1, Mar. 2023, doi: 10.32502/digital.v6i1.5162.
- [54] S. Sahyudi and A. Voutama, “Pengujian fungsional black box siska unsika dengan equivalence partitioning untuk validasi input dan output sistem,” *Volume*, vol. 8, pp. 148–155, 2025, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsk/index>







LAMPIRAN

Lampiran 1 *Black Box Testing*

a. Pengujian User










Tabel 11 Hasil Pengujian User







Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Akses beranda	Mengakses halaman website 	Menampilkan halaman beranda 	Berhasil
Akses menu prediksi	Klik menu “Prediksi” 	Menampilkan pilihan komoditas prediksi 	Berhasil
Akses prediksi Jagung	Klik komoditas “Jagung” 	Menampilkan halaman prediksi Jagung 	Berhasil
Input tahun tanam	Mengisi kolom tahun prediksi 	Data tahun dapat diinput 	Berhasil
Input bulan tanam	Mengisi kolom bulan tanam 	Data bulan dapat diinput 	Berhasil
Input variabel iklim	Mengisi lama penyinaran, curah hujan, indeks ENSO, suhu udara, kelembaban 	Data variabel iklim dapat diinput 	Berhasil









Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
			
Validasi input tidak lengkap	Klik tombol “Hitung Prediksi” tanpa melengkapi data 	Sistem menampilkan pesan error 	Berhasil
Proses prediksi	Klik tombol “Hitung Prediksi” dengan data lengkap 	Sistem memproses data dan menampilkan hasil prediksi 	Berhasil
Tampilan hasil prediksi	Setelah prediksi berhasil 	Sistem menampilkan estimasi bulan panen dan prediksi panen dalam ton 	Berhasil
Tampilan kategori prediksi	Setelah prediksi berhasil 	Sistem menampilkan keterangan sesuai kategori produksi (rendah, sedang, atau tinggi) 	Berhasil
Tampilan rekomendasi	Setelah prediksi berhasil 	Sistem menampilkan hasil prediksi dan rekomendasi 	Berhasil




b. Pengujian Admin

Tabel 12 Hasil Pengujian Admin

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Login Admin	Masuk ke halaman login admin 	Menampilkan halaman login admin 	Berhasil
Input <i>username</i>	Mengisi kolom <i>username</i> 	<i>Username</i> dapat diinput 	Berhasil
Input password	Mengisi kolom password 	<i>Password</i> dapat diinput 	Berhasil
Validasi salah inputan	Klik tombol “Masuk ke Dashbord” dengan data yang salah 	Sistem menampilkan pesan eror 	Berhasil
Akses dashboard admin	Klik tombol “Masuk ke Dashbord” dengan data yang benar 	Menampilkan dashboard admin 	Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Akses kelola prediksi	Klik menu “Kelola Prediksi” 	Menampilkan halaman kelola prediksi 	Berhasil
Akses kelola prediksi Jagung	Klik pilihan kelola prediksi Jagung 	Menampilkan halaman kelola prediksi Jagung 	Berhasil
Akses kelola dataset	Klik pilihan “Kelola Dataset” 	Menampilkan halaman kelola dataset 	Berhasil
Input data baru	Mengisi kolom tahun, bulan, prediksi, variabel iklim, dan produksi Jagung 	Data tahun, bulan, prediksi, variabel iklim, dan produksi Jagung dapat diinputkan 	Berhasil
Konfirmasi simpan data baru	Klik button “Simpan ke Dataset” 	Sistem menampilkan konfirmasi 	Berhasil
Simpan dataset baru	Klik button “Ya, Simpan” 	Data tersimpan di database dan riwayat dataset terdaftar 	Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Akses Edit data	Pilih salah satu data lalu klik tombol edit 	Menampilkan data yang akan diedit 	Berhasil
Melakukan edit data	Mengganti data yang ada dengan data baru 	Data dapat diubah ke data baru 	Berhasil
Konfirmasi edit data	Klik button “Simpan Perubahan” 	Sistem menampilkan konfirmasi 	Berhasil
Simpan data	Klik button “Simpan” 	Data tersimpan di <i>database</i> dan riwayat dataset terdaftar 	Berhasil
Akses hapus data	Pilih salah satu data lalu klik tombol hapus 	Sistem menampilkan konfirmasi 	Berhasil
Konfirmasi edit data	Klik “Hapus Data” 	Data terhapus dari <i>database</i> dan riwayat dataset terdaftar 	Berhasil
Akses simulasi prediksi	Klik menu “Simulasi Prediksi” 	Menampilkan halaman simulasi prediksi	Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
			
Input tahun tanam	Mengisi kolom tahun prediksi 	Data tahun dapat diinput 	Berhasil
Input bulan tanam	Mengisi kolom bulan tanam 	Data bulan dapat diinput 	Berhasil
Input variabel iklim	Mengisi lama penyinaran, curah hujan, indeks ENSO, suhu udara, kelembaban 	Data variabel iklim dapat diinput 	Berhasil
Validasi input tidak lengkap	Klik tombol “Hitung Prediksi” tanpa melengkapi data 	Sistem menampilkan pesan error 	Berhasil
Proses prediksi	Klik tombol “Hitung Prediksi” dengan data lengkap 	Sistem memproses data dan menampilkan hasil prediksi 	Berhasil

Skenario Pengujian	Langkah Pengujian	Hasil yang diharapkan	Hasil Pengujian
(1)	(2)	(3)	(4)
Tampilan hasil prediksi	Setelah prediksi berhasil 	Sistem menampilkan estimasi bulan panen dan prediksi panen dalam ton 	Berhasil
Tampilan kategori prediksi	Setelah prediksi berhasil 	Sistem menampilkan keterangan sesuai kategori produksi (rendah, sedang, atau tinggi) 	Berhasil
Tampilan rekomendasi	Setelah prediksi berhasil 	Sistem menampilkan hasil prediksi dan rekomendasi 	Berhasil

Lampiran 2 Kode Model XGBoost Baseline

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import os

from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error

# =====
# LOAD DATA
# =====
df = pd.read_excel("data jagung.xlsx")

# =====
# 2. PROSES LAGGING (SEMUA VARIABEL IKLIM)
# =====
kolom_fitur = ['LPM (%)', 'CH (mm)', 'ONI', 'Suhu (°C)', 'Kelembaban (%)']

for col in kolom_fitur:
    df[f'{col}_Lag1'] = df[col].shift(1)
    df[f'{col}_Lag2'] = df[col].shift(2)
    df[f'{col}_Lag3'] = df[col].shift(3)

df_clean = df.dropna().reset_index(drop=True)

# =====
# FITUR (X) & TARGET (y)
# =====
features = [col for col in df_clean.columns if 'Lag' in col]
X = df_clean[features]
y = df_clean['P (ton)']

# =====
# 4. SPLIT DATA
# =====
X_train, X_test, y_train, y_test = train_test_split(
    X, y,
    test_size=0.2,
    random_state=42 )

# =====
# MODEL XGBOOST
# =====
xgb = XGBRegressor(
    n_estimators=100,
```

```

        learning_rate=0.3,
        max_depth=6,
        subsample=1,
        colsample_bytree=1,
        random_state=42
    )
xgb.fit(X_train, y_train)

# =====
# PREDIKSI SELURUH DATA (57 BARIS)
# =====
y_all_pred = xgb.predict(X)

# =====
# 7. EVALUASI (SELURUH DATA)
# =====
r2_all = r2_score(y, y_all_pred)
mae_all = mean_absolute_error(y, y_all_pred)
rmse_all = np.sqrt(mean_squared_error(y, y_all_pred))

# =====
# VISUALISASI GRAFIK 57 BULAN
# =====
date_range = pd.date_range(start='2020-04-01', periods=len(y),
                             freq='MS')
date_labels = [d.strftime('%b-%y') for d in date_range]

plt.figure(figsize=(16, 8))

plt.plot(date_labels, y.values,
         label='Data Aktual (Asli)',
         color='#1f77b4',
         marker='o',
         linewidth=2)

plt.plot(date_labels, y_all_pred,
         label='Prediksi XGBoost',
         color='#d62728',
         linestyle='--',
         marker='s',
         alpha=0.8)

info_box = (f"Statistik Model (57 Bulan):\n"
            f"R2 Score: {round(r2_all, 3)}\n"
            f"MAE: {round(mae_all, 2)} Ton\n"
            f"RMSE: {round(rmse_all, 2)} Ton")

plt.gca().text(0.02, 0.95,
               info_box,
               transform=plt.gca().transAxes,

```

```

        fontsize=12,
        verticalalignment='top',
        bbox=dict(boxstyle='round', facecolor='white',
alpha=0.9))

plt.title('Grafik Prediksi Produksi Jagung (Baseline)',
        fontsize=16, pad=20)

plt.xlabel('Periode Waktu (Bulan-Tahun)', fontsize=12)
plt.ylabel('Produksi Jagung (Ton)', fontsize=12)
plt.xticks(rotation=45, fontsize=9)
plt.legend(loc='upper right', fontsize=11)
plt.grid(True, linestyle=':', alpha=0.6)

plt.tight_layout()

# --- BAGIAN MODIFIKASI PENYIMPANAN ---
# 1. Memastikan folder 'grafik' ada di direktori kerja saat ini
if not os.path.exists("grafik"): os.makedirs("grafik")

plt.show()
plt.close()

# =====
# OUTPUT HASIL DI TERMINAL
# =====
print("\n" + "="*40)
print(f"HASIL AKHIR R²: {r2_all:.3f}")
print(f"HASIL AKHIR MAE: {mae_all:.2f} Ton")
print(f"HASIL AKHIR RMSE: {rmse_all:.2f} Ton")
print("="*40)

# =====
# FEATURE IMPORTANCE
# =====
importances = pd.Series(xgb.feature_importances_, index=features)
importances = importances.sort_values(ascending=False)

print("\nTOP 5 VARIABEL PALING BERPENGARUH:")
print(importances.head(5) * 100)

```

Lampiran 3 Kode Model Optimasi XGBoost

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import os

from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split, RandomizedSearchCV
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error

# =====
# LOAD DATA & PREPROCESSING
# =====
df = pd.read_excel("data jagung.xlsx")
kolom_fitur = ['LPM (%)', 'CH (mm)', 'ONI', 'Suhu (°C)', 'Kelembaban (%)']

for col in kolom_fitur:
    df[f'{col}_Lag1'] = df[col].shift(1)
    df[f'{col}_Lag2'] = df[col].shift(2)
    df[f'{col}_Lag3'] = df[col].shift(3)

df_clean = df.dropna().reset_index(drop=True)
features = [col for col in df_clean.columns if 'Lag' in col]
X = df_clean[features]
y = df_clean['P (ton)']

# Split data (shuffle=False untuk menjaga urutan waktu)
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, shuffle=False, )

# =====
# RANDOM SEARCH OPTIMIZATION
# =====
param_dist = {
    'n_estimators': [50, 100, 200, 300],
    'max_depth': [3, 4, 5, 6],
    'learning_rate': [0.01, 0.05, 0.1, 0.3],
    'subsample': [0.7, 0.8, 0.9, 1.0],
    'colsample_bytree': [0.7, 0.8, 0.9, 1.0]
}

xgb_base = XGBRegressor(random_state=42, n_jobs=1)
search = RandomizedSearchCV(
    estimator=xgb_base,
    param_distributions=param_dist,
    n_iter=20,
    cv=3,
    scoring='r2',
```

```

        n_jobs=-1, # Menggunakan semua core
        random_state=42
    )
    search.fit(X_train, y_train)

    # Ambil model terbaik
    model = search.best_estimator_
    print("Best Params:", search.best_params_)
    y_all_pred = model.predict(X)

    # =====
    # EVALUASI (SELURUH DATA)
    # =====
    r2_all = r2_score(y, y_all_pred)
    mae_all = mean_absolute_error(y, y_all_pred)
    rmse_all = np.sqrt(mean_squared_error(y, y_all_pred))

    # =====
    # VISUALISASI
    # =====
    date_range = pd.date_range(start='2020-04-01', periods=len(y),
                                freq='MS')
    date_labels = [d.strftime('%b-%y') for d in date_range]

    plt.figure(figsize=(16, 8))
    plt.plot(date_labels, y.values, label='Data Aktual (Asli)',
             color='#1f77b4', marker='o', linewidth=2)
    plt.plot(date_labels, y_all_pred, label='Prediksi XGBoost (Optimasi)',
             color='#d62728', linestyle='--', marker='s', alpha=0.8)

    y_combined = np.concatenate([y.values, y_all_pred])
    y_min = y_combined.min()
    y_max = y_combined.max()

    # Memberikan sedikit 'ruang' (padding) sebesar 10% agar grafik tidak
    # menempel di tepi atas/bawah
    padding = (y_max - y_min) * 0.1
    plt.ylim(y_min - padding, y_max + padding)

    info_box = (f"Statistik Model (Optimasi):\n"
                f"R2 Score: {round(r2_all, 3)}\n"
                f"MAE: {round(mae_all, 2)} Ton\n"
                f"RMSE: {round(rmse_all, 2)} Ton")

    plt.gca().text(0.02, 0.95, info_box, transform=plt.gca().transAxes,
                  fontsize=12,
                  verticalalignment='top', bbox=dict(boxstyle='round',
                  facecolor='white', alpha=0.9))

```

```

plt.title('Grafik Prediksi Produksi (Optimasi Random Search)',
          fontsize=16, pad=20)
plt.xlabel('Periode Waktu', fontsize=12)
plt.ylabel('Produksi (Ton)', fontsize=12)
plt.xticks(rotation=45, fontsize=9)
plt.legend(loc='upper right', fontsize=11)
plt.grid(True, linestyle=':', alpha=0.6)
plt.tight_layout()

if not os.path.exists("grafik"): os.makedirs("grafik")
plt.savefig("grafik/grafik_jagung_optimasi_RS.png", dpi=300,
           bbox_inches='tight')
plt.show()

# =====
# OUTPUT & FEATURE IMPORTANCE
# =====
print(f"\nHASIL AKHIR R2: {r2_all:.3f}")
print(f"HASIL AKHIR MAE: {mae_all:.2f} Ton")
print(f"HASIL AKHIR RMSE: {rmse_all:.2f} Ton")
importances = pd.Series(model.feature_importances_,
                        index=features).sort_values(ascending=False)
print("\nTOP 5 VARIABEL:\n", importances.head(5) * 100)

```

Lampiran 4 Kode train-jagung.py

```
import os
import sys
import joblib
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from supabase import create_client, Client
from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_absolute_error,
mean_squared_error

url = "https://ooytznctvpdjsvbkpqtd.supabase.co"
key = "sb_publishable_jtHY1NMtcfh1Bzjr3nOpBA_2fVODiy8"
supabase = create_client(url, key)

def update_metadata_to_supabase(supabase_client, komoditas, r2,
model_name):
    # R2 diubah ke string persentase
    r2_str = f"{r2 * 100:.2f}%"

    # Update dokumen metadata/akurasi_model
    data = {
        "komoditas": komoditas.lower(),
        "r2": r2_str,
        "model_name": model_name
    }
    supabase_client.table("metadata").upsert(data,
on_conflict="komoditas").execute()
    print(f"✓ Metadata {komoditas} di Supabase telah diperbarui")

def jalankan_training_jagung(supabase_client: Client):
    """
    Fungsi core untuk melakukan retraining model jagung menggunakan
    objek supabase_client
    yang dikirimkan langsung dari server FastAPI utama (main.py).
    """
    # Menentukan lokasi absolut skrip
    BASE_DIR = os.path.dirname(os.path.abspath(__file__))
    CHART_DIR = os.path.join(BASE_DIR, "..", "static", "charts")
    MODEL_DIR = os.path.join(BASE_DIR, "..", "models")

    # Buat folder jika belum ada
    for folder in [CHART_DIR, MODEL_DIR]:
        if not os.path.exists(folder):
```

```

        os.makedirs(folder)

    print("--- Mengambil Data Jagung Terbaru dari Supabase ---")
    # Mengambil data dari tabel 'data_jagung' diurutkan berdasarkan
    tahun
    response =
supabase_client.table('data_jagung').select('*').order('tahun').execute()
    data_list = response.data

    if not data_list:
        print("Error: Tidak ada data jagung di Supabase untuk
    ditraining. Periksa kembali dokumen Anda.")
        return False

    df = pd.DataFrame(data_list)

    # Sinkronisasi 1: Paksa nama kolom hasil tarikan Supabase
    menjadi huruf kapital semua
    df.columns = [str(col).strip().upper() for col in df.columns]

    # --- PEMBERSIHAN DATA ---
    def clean_number(value):
        if pd.isna(value): return 0.0
        try:
            # Mengatasi jika data bertipe string dengan format koma
Indonesia (e.g. "159,0" menjadi 159.0)
            if isinstance(value, str):
                value = value.replace('.', '').replace(',', '.')
            return float(value)
        except:
            return 0.0

    # Disesuaikan dengan nama kolom kapital setelah standarisasi
    (PRODUKSI menggantikan P)
    cols_to_clean = ['LPM', 'CH', 'ONI', 'SUHU', 'KELEMBABAN',
    'PRODUKSI']
    for col in cols_to_clean:
        if col in df.columns:
            df[col] = df[col].apply(clean_number)

    # Sinkronisasi 2: Menangani variasi penulisan bulan oleh admin
    (Contoh: "Januari", "januari")
    month_map = {
        'januari': 1, 'februari': 2, 'maret': 3, 'april': 4,
        'mei': 5, 'juni': 6, 'juli': 7, 'agustus': 8,

```

```

        'september': 9, 'oktober': 10, 'november': 11, 'desember':
12     }

    if 'BULAN' in df.columns and 'TAHUN' in df.columns:
        df['BULAN_CLEAN'] =
df['BULAN'].astype(str).str.lower().str.strip()
        df['BULAN_NUM'] = df['BULAN_CLEAN'].map(month_map)
        df['BULAN_NUM'] = df['BULAN_NUM'].fillna(1).astype(int) #
Fallback aman jika kosong

        # [DIPINDAHKAN KE SINI]: Data disorting SEBELUM fitur
lagging dibuat agar runtun
        df = df.sort_values(['TAHUN',
'BULAN_NUM']).reset_index(drop=True)

        # =====
        # 2. PREPROCESSING & LAGGING
        # =====
        kolom_fitur = ['LPM', 'CH', 'ONI', 'SUHU', 'KELEMBABAN']

        # Sekarang fungsi .shift() di bawah ini aman karena datanya
dipastikan sudahurut kronologis
        for col in kolom_fitur:
            df[f'{col}_LAG1'] = df[col].shift(1)
            df[f'{col}_LAG2'] = df[col].shift(2)
            df[f'{col}_LAG3'] = df[col].shift(3)

        # Urutan fitur akhir: LPM_LAG1, LPM_LAG2, LPM_LAG3, CH_LAG1,
CH_LAG2...
        features = []
        for col in kolom_fitur:
            features.extend([f'{col}_LAG1', f'{col}_LAG2',
f'{col}_LAG3'])

        df_clean_g = df.dropna(subset=[f'{col}_LAG3' for col in
kolom_fitur]).reset_index(drop=True)

        t_low = df['PRODUKSI'].quantile(0.33) # Menggunakan tercil
sesuai penyesuaian (0.33)
        t_high = df['PRODUKSI'].quantile(0.66)

        best_params = {
            'n_estimators': 200,
            'max_depth': 3,
            'learning_rate': 0.05,
            'subsample': 1.0,

```

```

        'colsample_bytree': 0.9,
    }

# =====
# 3. PROSES GRAFIK EVALUASI
# =====
print("--- Mengoptimasi Model Grafik Jagung ---")
X_g = df_clean_g[features]
y_g = df_clean_g['PRODUKSI']

# Gunakan train_test_split dengan shuffle=False untuk
mempertahankan urutan waktu historis
X_train_g, X_test_g, y_train_g, y_test_g = train_test_split(X_g,
y_g, test_size=0.2, shuffle=False)

# Fit tunggal & deterministik dengan parameter tetap (lihat
catatan best_params di atas).
# n_jobs=1 + tree_method="exact" memaksa XGBoost single-thread
tanpa randomness
# urutan floating-point antar core, sehingga hasilnya
reproducible.
best_model_grafik = XGBRegressor(
    **best_params,
    random_state=42,
    n_jobs=1,
    tree_method="exact",
)
best_model_grafik.fit(X_train_g, y_train_g)

# Prediksi SELURUH DATA untuk visualisasi grafik historis
y_all_pred = best_model_grafik.predict(X_g)

r2_all = r2_score(y_g, y_all_pred)
mae_all = mean_absolute_error(y_g, y_all_pred)
rmse_all = np.sqrt(mean_squared_error(y_g, y_all_pred))

y_test_pred = best_model_grafik.predict(X_test_g)
r2_test = r2_score(y_test_g, y_test_pred)
print(f"Skor R2 pada data yang tidak dilihat model (Test Set):
{r2_test}")
# =====
# 4. PROSES MODEL APK (SHIFTED T+3)
# =====
print("--- Mengoptimasi Model APK Jagung (Shifted T+3) ---")
df_shifted = df.copy()
df_shifted['TARGET_PRODUKSI'] = df_shifted['PRODUKSI'].shift(-3)

```

```

df_clean_m = df_shifted.dropna(subset=['TARGET_PRODUKSI'] +
[f'{col}_LAG3' for col in kolom_fitur]).reset_index(drop=True)
X_m = df_clean_m[features]
y_m = df_clean_m['TARGET_PRODUKSI']

# Latih ulang parameter terbaik dengan data shift (transfer
learning) untuk kebutuhan APK
best_model_apk = best_model_grafik
best_model_apk.fit(X_m, y_m)

# Simpan bundle model.pkl resmi jagung
joblib.dump({
    'model': best_model_apk,
    'features': features,
    'best_hyperparameters': best_params,
    'thresholds': {'q1': float(t_low), 'q2': float(t_high)}
}, os.path.join(MODEL_DIR, "model_jagung_shifted.pkl"))

# =====
# 5. VISUALISASI GRAFIK DI DASHBOARD WEB
# =====
df_clean_g['TANGGAL'] =
pd.to_datetime(df_clean_g['TAHUN'].astype(str) + '-' +
df_clean_g['BULAN_NUM'].astype(str) + '-1')
date_labels = df_clean_g['TANGGAL'].dt.strftime('%b-%y').values

plt.figure(figsize=(16, 8))
x_indexes = np.arange(len(y_g))

# Plot Data Aktual dan Prediksi (Sesuai standarisasi visual
teratur)
plt.plot(x_indexes, y_g.values, label='Data Aktual',
color='#1f77b4', marker='o', linewidth=1.5)
plt.plot(x_indexes, y_all_pred, label='Prediksi XGBoost
(Optimasi)', color='#d62728', linestyle='--', marker='s', alpha=0.8,
linewidth=1.5)

plt.xticks(x_indexes, date_labels, rotation=45, fontsize=8,
ha='right')

# Kotak Informasi Statistik (Info Box)
info_box = (f"Statistik Model Jagung:\n"
f"R²: {round(r2_all, 3)}\n"
f"MAE: {round(mae_all, 2)} Ton\n"
f"RMSE: {round(rmse_all, 2)} Ton")

```

```

plt.gca().text(0.02, 0.95, info_box,
transform=plt.gca().transAxes, fontsize=12,
               verticalalignment='top',
bbox=dict(boxstyle='round', facecolor='white', alpha=0.9))

# Judul dan Labeling
plt.title('Grafik Analisis Histori: Produksi Jagung',
fontsize=14, pad=15)
plt.xlabel('Periode', fontsize=10)
plt.ylabel('Produksi (Ton)', fontsize=10)
plt.legend(loc='upper right')

plt.grid(True, linestyle='-', alpha=0.5)
plt.tight_layout()

# Simpan hasil grafik png untuk dashboard web
plt.savefig(os.path.join(CHART_DIR,
"grafik_prediksi_jagung.png"), dpi=150)
plt.close()

# Update hasil performa R2 ke tabel metadata Supabase
update_metadata_to_supabase(supabase_client, "Jagung", r2_all,
"Optimasi XGBoost")

print(f"✓ Training Jagung Selesai & Berhasil Disimpan. R²:
{r2_all:.3f}")
print("=====")
print("  THRESHOLD PRODUKSI (HASIL TRAINING)")
print(f"  Batas Rendah (Q1/33%): {t_low:.2f} Ton")
print(f"  Batas Tinggi (Q2/66%): {t_high:.2f} Ton")
print("=====")
return True

# Digunakan untuk pengujian mandiri jika file ini dijalankan
langsung (bukan via main.py)
if __name__ == "__main__":
    SUPABASE_URL = "https://ooytznctvpdjsvbkpqtd.supabase.co"
    SUPABASE_KEY = "sb_publishable_jtHY1NMtcfh1Bzjr3n0pBA_2fVODiy8"

    test_supabase = create_client(SUPABASE_URL, SUPABASE_KEY)
    jalankan_training_jagung(test_supabase)

```