

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, Support Vector Regression, Extreme Gradient Boosting (XGBoost), dan 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 (XGBoost)</i> 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

Kelembapan 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, kelembapan, curah hujan, serta intensitas cahaya terhadap pertumbuhan dan hasil jagung. Meskipun secara statistik pengaruhnya tidak selalu signifikan secara keseluruhan, faktor kelembapan 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.