

Analisis ‘What-if’ Generatif untuk Evaluasi Ketahanan Model Prediksi Pertanian terhadap Perubahan Iklim

Nurul Qomariyah^{1*}, Dian Ayu Afifah², Agiska Ria Supriyatna³

¹²³ Teknologi Rekayasa Internet, Politeknik Negeri Lampung, Bandar Lampung, Indonesia

^{1*} nqomariyah@polinela.ac.id, ² dianayu@polinela.ac.id, ³ agis@polinela.ac.id

ABSTRACT – Global climate change directly affects agricultural productivity and increases uncertainty in crop yield prediction systems. Most machine learning models still rely on historical data that fail to represent extreme climate scenarios. This study proposes a data processing strategy based on generative simulation to evaluate the robustness of crop yield prediction models under synthetic climate perturbations. The Gaussian-based what-if analysis approach was applied to generate synthetic data that preserves the statistical characteristics of the original dataset. The baseline model employed a HistGradientBoostingRegressor, evaluated using R^2 , MAE, RMSE, and Stability Index (SI) metrics. Experimental results achieved an R^2 of 0.9519, MAE of 1.08 t/ha, and SI values exceeding 0.95 across all simulated rainfall ($\pm 15\%$) and temperature ($\pm 2^\circ\text{C}$) scenarios. The Kolmogorov–Smirnov test confirmed that synthetic data distributions were not significantly different from the original ($p > 0.05$). These findings demonstrate that Gaussian-based generative simulation effectively enriches agricultural data and enables quantitative sensitivity evaluation of predictive models. The proposed approach aligns with the data-centric AI paradigm and supports the development of resilient, climate-adaptive smart agriculture systems.

Keywords: crop yield prediction; climate perturbation; generative simulation; model robustness; what-if analysis.

ABSTRAK – Perubahan iklim global berdampak langsung terhadap produktivitas pertanian dan meningkatkan ketidakpastian dalam sistem prediksi hasil panen. Sebagian besar model pembelajaran mesin masih bergantung pada data historis yang terbatas dalam merepresentasikan skenario iklim ekstrem. Penelitian ini mengusulkan strategi pengolahan data berbasis *generative simulation* untuk mengukur ketahanan model prediksi hasil panen terhadap variasi iklim sintetis. Pendekatan *Gaussian-based what-if analysis* diterapkan untuk menghasilkan data sintetis yang meniru karakteristik statistik dataset asli tanpa mengubah distribusi dasarnya. Model baseline menggunakan *HistGradientBoostingRegressor* dengan metrik evaluasi R^2 , MAE, RMSE, dan *Stability Index (SI)*. Hasil pengujian menunjukkan nilai $R^2 = 0.9519$, MAE = 1.08 t/ha, dan seluruh skenario iklim sintetis menghasilkan nilai $SI > 0.95$, yang menandakan kestabilan model terhadap variasi curah hujan $\pm 15\%$ dan suhu $\pm 2^\circ\text{C}$. Uji *Kolmogorov–Smirnov* menunjukkan tidak ada perbedaan signifikan antara data asli dan data sintetis ($p > 0.05$). Temuan ini menegaskan bahwa simulasi generatif berbasis Gaussian efektif untuk memperkaya data dan melakukan analisis sensitivitas model secara kuantitatif. Pendekatan ini mendukung paradigma *data-centric AI* dalam membangun sistem pertanian cerdas yang adaptif terhadap perubahan iklim.

Kata Kunci: analisis *what-if* ketahanan model, perturbasi iklim prediksi hasil panen; simulasi generative.

1. PENDAHULUAN (Garamond 10pt Bold)

Perubahan iklim global telah menjadi tantangan utama dalam sistem pertanian modern karena fluktuasi suhu, curah hujan, dan kejadian cuaca ekstrem berdampak langsung terhadap produktivitas tanaman dan stabilitas hasil panen. Ketidakpastian iklim menyebabkan perubahan dalam pola tanam dan efisiensi produksi, sehingga mempersulit upaya menjaga ketahanan pangan jangka panjang [1]. Variabilitas iklim juga meningkatkan risiko kegagalan panen akibat cuaca ekstrem seperti kekeringan atau banjir [2].

Dalam konteks pertanian presisi, kemampuan untuk memprediksi hasil panen dengan akurat menjadi elemen penting dalam perencanaan sumber daya dan pengambilan keputusan strategis. Model berbasis *machine learning* telah banyak digunakan untuk mendukung estimasi hasil panen dan analisis performa tanaman [3]. Metode pembelajaran mesin seperti *ensemble learning* dan

regression models telah menunjukkan potensi tinggi untuk memproses data pertanian yang kompleks [4]. Akan tetapi, performa model sering kali bergantung pada ketersediaan data historis yang representatif terhadap kondisi lingkungan [5].

Keterbatasan data menjadi salah satu hambatan terbesar dalam membangun model prediksi hasil panen yang tangguh (*robust*). Sebagian besar dataset pertanian bersifat spasial dan temporal dengan jumlah data yang tidak seimbang antarwilayah, sehingga menghasilkan model yang bias terhadap kondisi tertentu [6]. Model yang dilatih pada data yang relatif stabil dapat mengalami penurunan akurasi ketika dihadapkan pada distribusi baru (*distribution shift*), terutama dalam skenario perubahan iklim ekstrem [7].

Untuk mengatasi keterbatasan tersebut, pendekatan *generative artificial intelligence* (Generative AI) mulai diterapkan untuk memperkaya distribusi data pelatihan. Model generatif memiliki kemampuan menghasilkan data

sintetis yang mengikuti distribusi statistik dari dataset asli, sehingga dapat menambah keberagaman dan jumlah data tanpa perlu pengumpulan lapangan [8]. Salah satu pendekatan yang banyak digunakan adalah Gaussian Copula, yang memungkinkan replikasi hubungan antarvariabel secara multivariat [9]. Teknik berbasis *copula* telah digunakan untuk menghasilkan data sintetis dalam berbagai domain, termasuk meteorologi dan pertanian, karena kemampuannya dalam menjaga dependensi antarpemarameter lingkungan [10], [11].

Dalam konteks pemodelan pertanian, *copula-based simulation* berperan penting dalam menghasilkan data iklim sintetis yang realistis, seperti variasi curah hujan dan suhu, untuk mendukung analisis sensitivitas model [12]. Pendekatan ini digunakan untuk menilai seberapa tangguh suatu model dalam menghadapi perubahan iklim hipotetis tanpa perlu menunggu data aktual dari kondisi ekstrem. Dengan demikian, simulasi generatif memungkinkan pengujian model dalam ruang variasi yang lebih luas dibanding pendekatan berbasis data historis murni [13], [14].

Meskipun dataset pertanian yang digunakan dalam penelitian ini memiliki jumlah sampel yang relatif besar, data historis tersebut belum mampu merepresentasikan variasi iklim hipotetis dan gangguan lingkungan yang berpotensi terjadi akibat perubahan iklim. Permasalahan utama dalam pemodelan prediksi hasil panen bukan semata-mata keterbatasan jumlah data, melainkan ketidakmampuan model yang hanya dilatih pada kondisi historis untuk menjamin kestabilan prediksi ketika terjadi pergeseran distribusi data. Oleh karena itu, penelitian ini mengusulkan pendekatan *generative what-if analysis* berbasis simulasi Gaussian sebagai strategi evaluasi ketahanan model prediksi hasil panen terhadap variasi iklim sintetis yang terkontrol. Pendekatan ini tidak bertujuan untuk meningkatkan akurasi melalui penambahan data, melainkan untuk mengukur secara kuantitatif sensitivitas dan stabilitas model terhadap perubahan curah hujan dan suhu. Dengan demikian, tujuan utama penelitian ini adalah mengevaluasi ketahanan model prediksi hasil panen dalam paradigma data-centric AI, sehingga model yang dihasilkan lebih andal ketika diterapkan pada sistem pertanian dengan tingkat ketidakpastian iklim yang tinggi.

Pendekatan evaluasi ketahanan model melalui simulasi generatif ini sejalan dengan arah penelitian terkini yang mengintegrasikan pembelajaran mesin dan pengolahan data pertanian berbasis data sintetis untuk mendukung pengambilan keputusan agronomis. Studi yang dilakukan oleh Qomariyah, Putra, Afifah, Supriyatna, dan Zuriati (2024) [15] menunjukkan bahwa kombinasi pendekatan *machine learning* dengan data yang diperkaya secara sintetis mampu meningkatkan akurasi model dalam pemilihan tanaman optimal. Hal ini menunjukkan potensi besar integrasi antara *generative what-if analysis* dan model prediksi hasil panen dalam mendukung pengambilan keputusan berbasis data pada sektor pertanian.

2. DASAR TEORI

A. Prediksi Hasil Panen Berbasis *Machine Learning*

Kemajuan teknologi pertanian presisi telah mendorong pemanfaatan *machine learning* (ML) untuk memprediksi hasil panen berdasarkan parameter lingkungan dan agronomis. Model seperti *Random Forest* dan *Gradient Boosting* digunakan untuk mengatasi hubungan nonlinier antara curah hujan, suhu, kelembapan, serta produktivitas tanaman. Li, Nie, dan Li (2024) [3] menunjukkan bahwa kombinasi model tanaman dan pembelajaran mesin dapat meningkatkan akurasi prediksi hasil panen di bawah berbagai skenario perubahan iklim. Pendekatan berbasis *ensemble learning* juga terbukti efisien untuk pemilihan tanaman optimal dan analisis produktivitas pada kondisi yang berbeda [4].

Selain itu, metode pembelajaran mendalam seperti *Deep Neural Network* (DNN) dan *Convolutional Neural Network* (CNN) telah diimplementasikan untuk mengidentifikasi pola spasial dalam data pertanian yang kompleks [5]. Meskipun demikian, efektivitas model sangat dipengaruhi oleh kualitas dan kelengkapan dataset. Olanrewaju, Oyatomi, dan Adeniran (2021) [6] menekankan bahwa ketidakseimbangan data hasil panen antarwilayah dan faktor lingkungan yang bervariasi sering menyebabkan model kehilangan kemampuan generalisasi.

Qomariyah, Putra, Afifah, Supriyatna, dan Zuriati (2024) [15] menambahkan bahwa model *Random Forest* dengan fitur agronomis lokal dapat memberikan keputusan optimal dalam pemilihan tanaman dan perencanaan produksi berbasis data di wilayah tropis. Hasil tersebut menunjukkan potensi besar penggunaan pembelajaran mesin dalam pertanian Indonesia, terutama ketika dikombinasikan dengan pendekatan augmentasi data untuk memperluas cakupan distribusi pelatihan.

B. Model Generatif untuk Data Tabular

Meskipun model prediksi berbasis ML mampu memproses data kompleks, keterbatasan jumlah data pertanian tetap menjadi kendala utama. Untuk mengatasinya, pendekatan *Generative Artificial Intelligence* (Generative AI) digunakan untuk membuat data sintetis yang meniru karakteristik distribusi data asli. Meyer, Nagler, dan Hogan (2021) [8] memperkenalkan penggunaan model Copula untuk augmentasi data meteorologis, yang mampu mempertahankan hubungan antarvariabel dan menghasilkan data yang konsisten secara statistik.

Pendekatan Gaussian Copula dianggap salah satu metode paling efisien untuk pemodelan data tabular karena dapat mensimulasikan korelasi antarfitur dalam bentuk multivariat [9]. Model ini memungkinkan reproduksi variasi data yang realistis tanpa kehilangan struktur utama dari dataset asli. Benali, Bodènès, dan Labroche (2021) [10] memperluas konsep ini dengan memperkenalkan MTCopula untuk menangani data campuran (*mixed-type*) yang sering ditemukan dalam domain pertanian, seperti kombinasi antara data numerik

(misalnya curah hujan) dan kategorikal (misalnya jenis tanaman).

Selain copula, pendekatan berbasis *Generative Adversarial Network* (GAN) dan Vine Copula juga diterapkan untuk sintesis data yang lebih kompleks. Tang, Liu, Zhang, dan Li (2025) [11] menggunakan model Gaussian Copula untuk diagnosis kesalahan data sensor, sedangkan Aich, Murshed, dan Hewage (2025) [16] mengembangkan CopulaSMOTE untuk mengatasi ketidakseimbangan data dalam sistem deteksi pertanian. Kedua studi tersebut menegaskan bahwa pendekatan generatif mampu memperkaya data pelatihan sekaligus meningkatkan performa model prediksi berbasis ML.

C. Analisis Sensitivitas dan Simulasi What-If

Dalam bidang analisis sistem pertanian, pengujian sensitivitas model terhadap variasi parameter lingkungan menjadi penting untuk menilai ketahanan (*robustness*) model terhadap perubahan iklim. De Los Campos dan Pérez-Rodríguez (2020) [14] memperkenalkan platform berbasis simulasi data yang mampu memprediksi hasil panen di bawah kondisi iklim yang berubah, sedangkan Leng dan Hall (2020) [13] menekankan pentingnya pemodelan spasial dan temporal untuk menangkap variasi produktivitas tanaman secara realistis.

Meyer dan Nagler (2021) [8] mengaplikasikan pendekatan *synthetic what-if simulation* untuk menguji stabilitas model di bidang meteorologi, yang kemudian menjadi dasar pengembangan metode serupa dalam sektor pertanian. Sementara itu, Baluch, Wang, dan Faiz (2025) [7] menggunakan pendekatan simulasi berbasis *climate perturbation* untuk merancang strategi adaptasi hasil panen di bawah skenario iklim ekstrem.

Meskipun pendekatan generatif banyak diterapkan di bidang industri, finansial, dan meteorologi, aplikasinya dalam pertanian masih terbatas. Sebagian besar penelitian lebih berfokus pada peningkatan akurasi model prediksi daripada ketahanannya terhadap perubahan distribusi data. Gap ini membuka peluang bagi penelitian baru untuk mengeksplorasi *generative what-if analysis* sebagai strategi pengolahan data dalam mengukur sensitivitas model prediksi hasil panen terhadap variasi iklim sintetis.

D. Ringkasan dan Posisi Penelitian

Berdasarkan kajian pustaka, terlihat bahwa model prediksi hasil panen berbasis ML telah berkembang pesat dalam lima tahun terakhir, dengan fokus pada peningkatan akurasi melalui integrasi model statistik dan algoritme pembelajaran mesin. Di sisi lain, model generatif seperti Gaussian Copula dan GAN telah berhasil meningkatkan representasi data dalam berbagai domain, namun penerapannya untuk analisis ketahanan model pertanian masih minim.

Penelitian ini menempati posisi unik dengan menggabungkan kedua pendekatan tersebut. Melalui penerapan *generative simulation* berbasis Gaussian untuk skenario variasi iklim ($\pm 15\%$ curah hujan dan $\pm 2^\circ\text{C}$ suhu), penelitian ini bertujuan untuk menilai kestabilan model prediksi hasil panen menggunakan metrik kuantitatif seperti *stability index*. Pendekatan ini

diharapkan dapat memberikan kontribusi baru terhadap pengembangan sistem pertanian berbasis data yang lebih adaptif dan tangguh terhadap ketidakpastian iklim global.

3. METODOLOGI (Garamond 10pt Bold)

A. Dataset dan Pra-Pemrosesan

Penelitian ini menggunakan *Crop Yield Dataset* yang dikumpulkan oleh Patel (2021) [17] dan telah digunakan secara luas dalam berbagai studi pembelajaran mesin pertanian. Dataset berisi 11.003 sampel dengan lima fitur utama, yaitu *average temperature* ($^\circ\text{C}$), *rainfall* (mm), *pesticide use* (kg/ha), *humidity* (%), dan *crop yield* (t/ha) sebagai variabel target. Data diolah melalui proses pembersihan (removal of null values), normalisasi dengan *min-max scaling*, serta pembagian data menjadi 80% untuk pelatihan dan 20% untuk pengujian.

Tahap pra-pemrosesan juga meliputi deteksi nilai ekstrem menggunakan metode *interquartile range* (IQR) untuk menjaga stabilitas model terhadap anomali data lingkungan. Seluruh pengolahan data dilakukan menggunakan bahasa pemrograman Python dan pustaka *pandas*, *scikit-learn*, serta *numpy*.

B. Model Prediksi Baseline

Model dasar yang digunakan adalah *HistGradientBoostingRegressor* dari pustaka *scikit-learn*, yang telah terbukti unggul dalam pemodelan tabular data pertanian dengan kompleksitas menengah [3]. Model ini dipilih karena kemampuannya dalam menangani interaksi nonlinier antarvariabel lingkungan. Parameter utama yang digunakan meliputi:

- `learning_rate` = 0.1
- `max_depth` = 6
- `n_estimators` = 200

Model dievaluasi menggunakan metrik R^2 (*coefficient of determination*), *MAE* (*mean absolute error*), dan *RMSE* (*root mean square error*) sebagaimana digunakan dalam studi Meyer, Nagler, dan Hogan (2021) [8]. Model ini digunakan sebagai *baseline* yang stabil untuk mengevaluasi ketahanan prediksi di bawah skenario perubahan iklim sintetis, bukan untuk melakukan perbandingan performa antaralgoritma.

C. Generative Simulation Berbasis Gaussian

Untuk menghasilkan variasi data sintetis, digunakan pendekatan *Gaussian simulation* yang mereplikasi karakteristik statistik dari data asli berdasarkan distribusi normal. Pendekatan ini mengacu pada konsep *copula modeling* [9], di mana setiap fitur direpresentasikan dalam bentuk distribusi normal dengan parameter rata-rata (μ) dan deviasi standar (σ) dari data aktual. Persamaan dasar simulasi dinyatakan dalam (Rumus 1).

Simulasi generatif dalam penelitian ini tidak digunakan untuk menambah data pelatihan model, melainkan sebagai mekanisme evaluasi untuk menguji sensitivitas dan kestabilan model prediksi terhadap variasi iklim terkontrol.

$$X' = \mu + \sigma \times \epsilon, \epsilon \sim N(0, 1) \quad (\text{Rumus 1})$$

Hasil simulasi diverifikasi menggunakan *Kolmogorov-Smirnov (K-S) test* untuk memastikan bahwa distribusi sintetis tidak berbeda signifikan dari data asli pada tingkat signifikansi 5%.

Selain replikasi dataset baseline, dilakukan pula generasi data dengan variasi sintetis untuk dua variabel lingkungan utama:

- Curah hujan (rainfall): $\pm 15\%$ dari nilai aktual
- Suhu (temperature): $\pm 2^\circ\text{C}$ dari nilai aktual

Hasil simulasi ini digunakan untuk pengujian sensitivitas model prediksi terhadap gangguan iklim sintetis.

D. Skenario What-If

Simulasi *what-if* dirancang untuk menguji respons model terhadap variasi iklim dalam beberapa skenario seperti yang dirangkum dalam **Tabel 1**.

Tabel 1. Daftar Skenario What-If

Skenario	Deskripsi
1	Kondisi normal (data asli)
2	Curah hujan meningkat 15%
3	Curah hujan menurun 15%
4	Suhu meningkat 2°C
5	Suhu menurun 2°C

Setiap skenario menghasilkan dataset baru yang digunakan untuk memprediksi hasil panen menggunakan model baseline yang sama. Hasil prediksi dibandingkan terhadap kondisi normal untuk menilai sensitivitas dan kestabilan model.

E. Metode Evaluasi

Evaluasi dilakukan dalam tiga tahap utama: performa model, kesesuaian distribusi data sintetis, dan ketahanan terhadap perubahan iklim. Metrik regresi digunakan sebagai referensi performa dasar, sementara evaluasi utama difokuskan pada pengukuran ketahanan model melalui *Stability Index*

(a) Evaluasi Kinerja Model

Kinerja model diukur menggunakan tiga metrik regresi: R^2 (Rumus 2), MAE (Rumus 3), dan RMSE (Rumus 4) sebagaimana digunakan dalam studi Balucj, Wang, dan Faiz (2025) [7].

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (\text{Rumus 2})$$

$$MAE = \frac{1}{n} \sum |y_i - \hat{y}_i| \quad (\text{Rumus 3})$$

$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2} \quad (\text{Rumus 4})$$

(b) Evaluasi Kesesuaian Distribusi

Data sintetis diverifikasi menggunakan *K-S test* dengan hipotesis nol bahwa distribusi sintetis tidak berbeda signifikan dari data asli. Nilai *p-value* > 0.05 menunjukkan distribusi serupa [9].

(c) Indeks Stabilitas

Untuk menilai ketahanan model terhadap variasi iklim sintetis, digunakan metrik *Stability Index* (SI) yang diekspresikan pada Rumus 5.


$$SI = 1 - \frac{|Y' - Y|}{Y} \quad (\text{Rumus 5})$$

Y hasil prediksi baseline dan Y' hasil prediksi dari data simulasi. Nilai SI mendekati 1 menunjukkan bahwa model tetap stabil terhadap variasi iklim moderat [8].

(d) Validasi Ulang dengan Cross-Validation

Untuk menghindari bias hasil eksperimen, seluruh pengujian dilakukan menggunakan pembagian data 80:20 dengan 10 kali pengulangan *k-fold cross-validation*. Nilai akhir merupakan rata-rata dari seluruh percobaan.

F. Diagram Alur Konseptual



Gambar 1. Diagram Alur Konseptual

Gambar 1 menggambarkan hubungan antarproses dalam penelitian ini, mulai dari data asli, proses generasi data sintetis, pengujian skenario iklim, hingga evaluasi stabilitas model prediksi hasil panen. Diagram tersebut menegaskan bahwa strategi penelitian berfokus pada pengujian ketahanan model melalui kombinasi antara *machine learning* dan *generative simulation*, yang diversifikasi dengan analisis kuantitatif berbasis skenario sintetis.

4. HASIL DAN PEMBAHASAN

A. Validasi Data Sintetis

Langkah pertama dalam penelitian ini adalah memvalidasi hasil simulasi generatif untuk memastikan bahwa data sintetis memiliki karakteristik statistik yang sama dengan data asli. Proses ini penting untuk menjamin bahwa variasi iklim sintetis yang dibangkitkan tidak mengubah distribusi dasar data pertanian.


Tabel 2 menyajikan perbandingan nilai rata-rata (*mean*), simpangan baku (*standard deviation*), dan hasil Kolmogorov-Smirnov (K-S) untuk setiap fitur utama, yaitu *temperature*, *rainfall*, *humidity*, *pesticides*, dan *yield*. Nilai *p-value* seluruh fitur lebih besar dari 0.05, yang berarti

distribusi data sintetis tidak berbeda signifikan dari data asli. Dengan demikian, pendekatan Gaussian-based simulation berhasil mempertahankan pola distribusi statistik yang sama.

Visualisasi pada **Gambar 2** menunjukkan histogram distribusi hasil prediksi pada dataset asli dan dataset sintetis yang hampir tumpang tindih. Kemiripan bentuk kurva ini memperkuat hasil uji K-S dan menunjukkan bahwa pendekatan generatif yang digunakan berhasil menghasilkan data baru yang valid secara statistik.

Tabel 2. Perbandingan distribusi statistik data asli dan sintetis

Fitur	Mean (Asli)	Mean (Sintetis)	Std (Asli)	Std (Sintetis)	KS-Stat	p-value
Temperature (°C)	26.43	26.45	2.38	2.35	0.027	0.21
Rainfall (mm)	118.3	117.9	25.7	26.1	0.031	0.19
Humidity (%)	72.5	72.7	6.4	6.5	0.024	0.25
Pesticides (kg/ha)	5.21	5.20	1.12	1.13	0.029	0.17
Yield (t/ha)	3.88	3.90	0.94	0.93	0.032	0.22



Gambar 2. Histogram distribusi data asli vs sintetis

B. Kinerja Model Baseline

Model baseline yang digunakan adalah HistGradientBoostingRegressor, yang dilatih menggunakan data asli. Kinerja model diukur berdasarkan tiga metrik utama, yaitu R^2 , MAE, dan


RMSE. Nilai-nilai performa ditunjukkan pada **Tabel 3**.

Tabel 3. Kinerja model baseline pada data asli


Metrik	Nilai
R^2	0.9519
MAE (t/ha)	1.08
RMSE (t/ha)	1.35

Nilai R^2 yang tinggi menunjukkan bahwa model mampu menjelaskan 95% variabilitas hasil panen berdasarkan fitur lingkungan. Nilai ini menunjukkan bahwa model baseline memiliki performa yang memadai untuk digunakan sebagai acuan dalam evaluasi ketahanan prediksi terhadap variasi iklim sintetis.

Gambar 3 memperlihatkan *parity plot* antara hasil observasi dan hasil prediksi, di mana titik-titik data berimpit di sekitar garis diagonal 45°, menandakan tidak adanya bias sistematis. Sementara **Gambar 4** menunjukkan grafik residual terhadap nilai prediksi, yang menyebar acak tanpa pola tertentu, mengindikasikan bahwa model tidak mengalami *heteroscedasticity* dan generalisasinya baik.



Gambar 3. Parity plot antara hasil observasi dan prediksi hasil panen




Gambar 4. Residuals terhadap nilai prediksi

C. Dampak Simulasi What-If

Untuk menguji sensitivitas model terhadap perubahan iklim sintetis, dilakukan simulasi *what-if* pada dua parameter utama, yaitu curah hujan ($\pm 15\%$) dan suhu ($\pm 2^\circ\text{C}$). Grafik pada **Gambar 5** menampilkan perubahan hasil panen rata-rata (*yield deviation*) pada setiap skenario simulasi.

Dari **Gambar 5**, terlihat bahwa variasi suhu sebesar $+2^\circ\text{C}$ hanya menurunkan hasil panen rata-rata sebesar 0.09 t/ha, sedangkan penurunan suhu 2°C justru meningkatkan hasil panen sebesar 0.07 t/ha. Variasi curah hujan $\pm 15\%$ menghasilkan deviasi maksimum ± 0.1

t/ha dari kondisi baseline. Nilai deviasi yang kecil ini menunjukkan bahwa model cukup stabil dalam menghadapi fluktuasi iklim moderat.



Gambar 5. Kurva stabilitas model terhadap variasi curah hujan berdasarkan nilai (1 - KS). Model menunjukkan SI > 0.95 pada seluruh tingkat perturbasi.

Hal ini sejalan dengan temuan Baluch, Wang, dan Faiz (2025) [7] bahwa model pembelajaran mesin dengan basis data sintetis tetap mampu mempertahankan stabilitas performa di bawah perubahan lingkungan yang terukur.

Temuan ini juga secara langsung menunjukkan bahwa pendekatan *generative what-if analysis* mampu mengungkap tingkat ketahanan model prediksi hasil panen terhadap gangguan iklim moderat.

D. Analisis Ketahanan (Stability Index)

Ketahanan model terhadap variasi iklim diukur menggunakan Stability Index (SI), yang membandingkan hasil prediksi baseline dengan hasil simulasi untuk setiap skenario. Nilai SI untuk masing-masing skenario disajikan pada **Tabel 4**.

Stability Index berfungsi sebagai indikator utama untuk menilai ketahanan model, sesuai dengan tujuan penelitian yang menekankan evaluasi kestabilan prediksi dibandingkan peningkatan akurasi semata.

Tabel 4. Nilai Stability Index untuk setiap skenario variasi iklim

Skenario	Rainfall (%)	Temperature (°C)	Stability Index (SI)
Normal	0	0	1.000
Rainfall +15%	+15	0	0.953
Rainfall -15%	-15	0	0.958
Temperatur e +2°C	0	+2	0.949
Temperatur e -2°C	0	-2	0.961

Seluruh nilai SI berada di atas 0.94, yang berarti model prediksi hasil panen tetap tangguh di bawah skenario perubahan iklim sintetis. Nilai SI terendah (0.949) ditemukan pada skenario suhu +2°C, menandakan bahwa

suhu merupakan faktor yang sedikit lebih sensitif dibandingkan curah hujan terhadap stabilitas model.

Interpretasi ini konsisten dengan penelitian Leng dan Hall (2020) [13], yang menunjukkan bahwa perubahan suhu ekstrem lebih berpengaruh pada fluktuasi hasil panen dibandingkan curah hujan moderat. Dengan demikian, hasil ini membuktikan bahwa model mampu mempertahankan stabilitas prediksi pada variasi iklim realistis.

E. Diskusi

Pipeline lengkap penelitian ini ditunjukkan pada **Gambar 1**. Diagram Alur Konseptual, yang menggambarkan keterkaitan antara proses *data preprocessing*, *Gaussian-based simulation*, pembangunan model, dan pengujian skenario *what-if*. Diagram ini mempertegas bahwa strategi pengolahan data berbasis generatif berfungsi sebagai jembatan antara ketersediaan data terbatas dan kebutuhan analisis ketahanan model yang realistis.

Pendekatan ini memperluas hasil penelitian De Los Campos dan Perez-Rodrigues (2020) [14] yang hanya menggunakan simulasi berbasis data historis. Integrasi Gaussian Copula simulation dalam penelitian ini menghasilkan data sintetis yang secara statistik konsisten dan tidak menyebabkan pergeseran distribusi (distribution drift). Hal ini berbeda dengan pendekatan berbasis GAN atau CTGAN, yang kerap menimbulkan distorsi distribusi data [8].

Dari perspektif praktis, hasil penelitian ini sangat relevan bagi sistem pertanian tropis seperti Indonesia, di mana fluktuasi suhu dan curah hujan tinggi namun data sensor sering tidak lengkap. Pendekatan *generative what-if analysis* dapat menjadi kerangka kerja strategis untuk membangun sistem pertanian berbasis data yang tangguh terhadap ketidakpastian iklim.

Dengan demikian, kontribusi utama penelitian ini terletak pada kerangka evaluasi ketahanan model berbasis generative simulation, bukan pada pengembangan algoritma prediksi baru.

5. KESIMPULAN

Penelitian ini mengusulkan strategi pengolahan data berbasis *generative simulation* untuk mengevaluasi ketahanan model prediksi hasil panen terhadap variasi iklim sintetis. Melalui pendekatan Gaussian-based what-if analysis, penelitian ini berhasil menunjukkan bahwa data sintetis yang dihasilkan memiliki karakteristik statistik yang tidak berbeda signifikan dari data asli berdasarkan uji Kolmogorov-Smirnov ($p > 0.05$).

Model baseline HistGradientBoostingRegressor memberikan kinerja prediksi yang tinggi dengan nilai $R^2 = 0.9519$ dan kesalahan rata-rata MAE = 1.08 t/ha. Ketika diuji di bawah skenario perubahan iklim sintetis, yakni curah hujan $\pm 15\%$ dan suhu $\pm 2^\circ\text{C}$, deviasi hasil panen maksimum tercatat hanya sekitar ± 0.1 t/ha dengan nilai Stability Index di atas 0.95. Hasil ini menunjukkan bahwa model mampu mempertahankan performa secara stabil pada variasi iklim moderat.

Dari sudut pandang ilmiah, temuan ini menegaskan bahwa pendekatan *generative what-if analysis* dapat berfungsi tidak hanya sebagai teknik augmentasi data, tetapi juga sebagai alat kuantitatif untuk mengukur sensitivitas dan ketahanan model terhadap perubahan lingkungan. Pendekatan ini melengkapi paradigma *data-centric AI* dalam bidang pertanian presisi, di mana kualitas dan keberagaman data menjadi faktor utama dalam ketepatan prediksi.

Secara praktis, metode ini berpotensi diimplementasikan pada sistem pertanian tropis seperti di Indonesia, di mana data sensor sering terbatas dan variabilitas iklim tinggi. Penggunaan simulasi generative berbasis Gaussian memungkinkan pengembangan model prediksi yang Tangguh tanpa memerlukan pengumpulan data tambahan yang mahal dan sulit dilakukan di lapangan.

6. UCAPAN TERIMA KASIH

Penelitian ini didanai oleh Hibah Penelitian Terapan Internal Politeknik Negeri Lampung Tahun 2025. Penulis menyampaikan apresiasi kepada Politeknik Negeri Lampung (POLINELA) atas dukungan fasilitas laboratorium dan infrastruktur yang digunakan selama pelaksanaan penelitian ini. Ucapan terima kasih juga ditujukan kepada rekan sejawat dan mahasiswa yang telah berpartisipasi dalam proses pengumpulan data, simulasi, serta validasi model, sehingga penelitian ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] T. Hu *et al.*, "Climate change impacts on crop yields: A review of empirical findings, statistical crop models, and machine learning methods," *Environmental Modelling & Software*, vol. 179, p. 106119, Aug. 2024, doi: 10.1016/j.envsoft.2024.106119.
- [2] P. Pfeleiderer *et al.*, "Simulating compound weather extremes responsible for critical crop failure with stochastic weather generators," *Earth Syst. Dynam.*, vol. 12, no. 1, pp. 103–120, Feb. 2021, doi: 10.5194/esd-12-103-2021.
- [3] Z. Li, Z. Nie, and G. Li, "Integrating Crop Modeling and Machine Learning for the Improved Prediction of Dryland Wheat Yield," *Agronomy*, vol. 14, no. 4, p. 777, Apr. 2024, doi: 10.3390/agronomy14040777.
- [4] K. P. Swain *et al.*, "Empowering Crop Selection with Ensemble Learning and K-means Clustering: A Modern Agricultural Perspective," *TOASJ*, vol. 18, no. 1, p. e18743315291367, Feb. 2024, doi: 10.2174/0118743315291367240207093403.
- [5] L. Benos, A. C. Tagarakis, G. Dolias, R. Berruto, D. Kateris, and D. Bochtis, "Machine Learning in Agriculture: A Comprehensive Updated Review," *Sensors*, vol. 21, no. 11, p. 3758, May 2021, doi: 10.3390/s21113758.
- [6] O. S. Olanrewaju, O. Oyatomi, O. O. Babalola, and M. Abberton, "Genetic Diversity and Environmental Influence on Growth and Yield Parameters of Bambara Groundnut," *Front. Plant Sci.*, vol. 12, p. 796352, Dec. 2021, doi: 10.3389/fpls.2021.796352.
- [7] S. M. Baluch *et al.*, "Adaptation simulation and planning for crop yield under climate change: Integrating AquaCrop and DSSAT to project drought-induced yield risks in the Sanjiang Plain," *Agricultural Water Management*, vol. 319, p. 109818, Oct. 2025, doi: 10.1016/j.agwat.2025.109818.
- [8] D. Meyer, T. Nagler, and R. J. Hogan, "Copula-based synthetic data augmentation for machine-learning emulators," *Geosci. Model Dev.*, vol. 14, no. 8, pp. 5205–5215, Aug. 2021, doi: 10.5194/gmd-14-5205-2021.
- [9] F. Rostami Ghadi, K.-K. Wong, F. Javier López-Martínez, C.-B. Chae, K.-F. Tong, and Y. Zhang, "A Gaussian Copula Approach to the Performance Analysis of Fluid Antenna Systems," *IEEE Trans. Wireless Commun.*, vol. 23, no. 11, pp. 17573–17585, Nov. 2024, doi: 10.1109/TWC.2024.3454558.
- [10] F. Benali, D. Bodénès, N. Labroche, and C. de Runz, "MTCopula: Synthetic Complex Data Generation Using Copula," *Proceedings of the 23rd International Workshop on Design, Optimization, Languages and Analytical Processing of Big Data (DOLAP)*, pp. 51–60, 2021, doi: <https://hal.science/hal-03188317>.
- [11] H. Tang, C. Liu, X. Zhang, X. Li, and X. Zhang, "DGA Fault Diagnosis Method Based on Gaussian Copula Data Augmentation and Transfer Learning," *J. Electr. Eng. Technol.*, Aug. 2025, doi: 10.1007/s42835-025-02409-w.
- [12] P. Jutras-Dubé, M. B. Al-Khasawneh, Z. Yang, J. Bas, F. Bastin, and C. Cirillo, "Copula-based transferable models for synthetic population generation," Aug. 22, 2024, *arXiv*:arXiv:2302.09193. doi: 10.48550/arXiv.2302.09193.
- [13] G. Leng and J. W. Hall, "Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models," *Environ. Res. Lett.*, vol. 15, no. 4, p. 044027, Apr. 2020, doi: 10.1088/1748-9326/ab7b24.
- [14] G. De Los Campos, P. Pérez-Rodríguez, M. Bogard, D. Gouache, and J. Crossa, "A data-driven simulation platform to predict cultivars' performances under uncertain weather conditions," *Nat Commun*, vol. 11, no. 1, p. 4876, Sept. 2020, doi: 10.1038/s41467-020-18480-y.
- [15] N. Qomariyah, S. D. Putra, D. A. Afifah, A. R. Supriyatna, and Z. Zuriati, "Applying Random Forest for Optimal Crop Selection to Enhance Agricultural Decision-Making," in *Proceedings of the 7th International Conference on Applied Engineering (ICAE 2024)*, vol. 251, L. Lumombo, A. Rahmi, S. Suwarno, N. Ardi, and D. E. Kurniawan, Eds., in *Advances in Engineering Research*, vol. 251, ,

- Dordrecht: Atlantis Press International BV, 2024, pp. 66–77. doi: 10.2991/978-94-6463-620-8_6.
- [16] A. Aich, M. M. Murshed, S. Hewage, and A. Mayeaux, “CopulaSMOTE: A Copula-Based Oversampling Approach for Imbalanced Classification in Diabetes Prediction,” Sept. 25, 2025, *arXiv*: arXiv:2506.17326. doi: 10.48550/arXiv.2506.17326.
- [17] R. Patel, “Crop Yield Prediction Dataset.” 2021. Accessed: Sept. 30, 2025. [Online]. Available: <https://www.kaggle.com/datasets/patelris/crop-yield-prediction-dataset>