

Analisis Kinerja Model *Machine learning* dalam Prediksi Gagal Panen Gabah

Taufik Nizami¹, Muhammad Atillah Mustaqiim², Wahyudi Ariannor^{3*}

Teknik Informatika, STMIK Banjarbaru, Banjarbaru, Indonesia

*e-mail Corresponding Author: wahyu.arian@gmail.com

Abstract

In Banjar Regency, rice production faces significant challenges, including high crop failure rates and production variability across regions, which impact equitable food availability. This study aims to analyze the performance of various machine learning algorithms in predicting rice crop failures, a critical issue in food security. The research variables include factors such as weather, air humidity, soil conditions, agricultural variables, and tungro disease infestations. Several algorithms were tested, including Naive Bayes, Logistic Regression, Decision Tree, Random Forest, XGBoost, and others. Evaluation was conducted using cross-validation techniques with metrics such as accuracy, precision, recall, F1-Score, and ROC AUC. The results indicate that the Random Forest and XGBoost algorithms achieved the best performance, with accuracies of 77% and 70%, respectively. The study concludes that machine learning-based models can support better decision-making to mitigate crop failure risks. Furthermore, this research provides a foundation for the development of predictive models in the agricultural sector.

Keywords: Harvest failure; Rice; Machine learning; Prediction; Food security

Abstrak

Di Kabupaten Banjar, produksi gabah menghadapi kendala signifikan, termasuk gagal panen yang tinggi dan variasi produksi antar wilayah, yang memengaruhi ketersediaan pangan merata. Penelitian ini bertujuan untuk menganalisis kinerja berbagai algoritma *machine learning* dalam memprediksi gagal panen gabah, yang merupakan permasalahan penting dalam ketahanan pangan. Variabel penelitian mencakup faktor-faktor seperti cuaca, kelembapan udara, kondisi tanah, variabel pertanian, dan serangan tungro. Beberapa algoritma yang diuji meliputi *Naive Bayes*, *Logistic Regression*, *Decision Tree*, *Random Forest*, *XGBoost*, dan lainnya. Evaluasi dilakukan menggunakan teknik *cross-validation* dengan metrik akurasi, *precision*, *recall*, *F1-Score*, dan *ROC AUC*. Hasil menunjukkan bahwa algoritma *Random Forest* dan *XGBoost* memberikan performa terbaik, dengan akurasi masing-masing sebesar 77% dan 70%. Kesimpulan penelitian ini menunjukkan bahwa model berbasis *machine learning* dapat digunakan untuk mendukung pengambilan keputusan yang lebih baik dalam mengurangi risiko gagal panen. Penelitian ini juga memberikan dasar untuk pengembangan model prediksi di sektor agrikultur.

Kata kunci: Gagal panen; Gabah; Machine learning; Prediksi; Ketahanan pangan

1. Pendahuluan

Prediksi gagal panen gabah sangat penting untuk pertanian dan ketahanan pangan, mengingat gagal panen adalah risiko utama bagi petani akibat faktor seperti perubahan iklim, hama, dan penyakit tanaman. Prediksi adalah metode memperkirakan nilai masa depan berdasarkan data masa lalu dan kini. Meskipun hasil prediksi tidak selalu tepat, tujuannya adalah mendekati keakuratan untuk dijadikan acuan dalam pengambilan Keputusan [1] [2] [3]. Di Kabupaten Banjar, produksi gabah menghadapi kendala signifikan, termasuk gagal panen yang tinggi dan variasi produksi antar wilayah, yang memengaruhi ketersediaan pangan merata. Selain itu, keterbatasan data terkait cuaca, kualitas tanah, dan penyakit tanaman menyulitkan pemahaman penyebab gagal panen. Oleh karena itu, penerapan metode prediksi, terutama menggunakan teknik komputasi di era teknologi seperti sekarang menjadi langkah strategis untuk mendukung pengambilan keputusan yang lebih cerdas dalam mengurangi risiko gagal panen di

sektor pertanian gabah. Salah satu teknik komputasi yang dapat diterapkan yaitu teknik *machine learning*.

Machine learning adalah proses untuk mendapatkan pengetahuan dari data. Bidang ini merupakan gabungan antara statistik, kecerdasan buatan, dan ilmu komputer. Pembelajaran mesin juga sering disebut sebagai analitik prediktif atau pembelajaran statistik [4]. Teknik *machine learning* digunakan di berbagai bidang, termasuk pertanian, deteksi penipuan, dan media sosial [5]. Teknik *machine learning* dapat diterapkan untuk melakukan prediksi berbagai hal persoalan, seperti pada kasus prediksi panen gabah.

Pada penelitian ini dilakukan analisis kinerja model *machine learning* Regresi Logistik, *Extra Tree*, *Decision Tree C4.5*, *Support Vector Machine* (SVM), *Random Forest*, *XGBoost*, *Gradient Boosting* dan *Naive Bayes* untuk memprediksi hasil panen gabah sehingga dapat digunakan untuk mendukung pengambilan keputusan yang lebih baik dalam mengurangi risiko gagal panen.

2. Tinjauan Pustaka

Beberapa riset terdahulu yang relevan seperti penelitian [6], menggunakan algoritma regresi linier untuk memprediksi produksi tanaman padi di Kabupaten Grobogan, Jawa Tengah. Penurunan produksi padi yang terjadi pada tahun 2022 sebesar 4,62%, serta meningkatnya jumlah penduduk dan alih fungsi lahan menjadi faktor utama masalah produksi. Penelitian ini bertujuan untuk mengatasi ketidakpastian hasil panen dengan membangun model prediksi berdasarkan data dari Badan Pusat Statistik dan BMKG, yang mencakup variabel luas lahan, curah hujan, kelembapan, dan suhu selama sepuluh tahun terakhir. Hasil model regresi linier menunjukkan nilai MSE 6.550,24 dan MAE 121.247.657,98, dengan tingkat akurasi prediksi yang cukup baik. Model ini diharapkan dapat membantu merencanakan produksi yang lebih efisien dan mempertahankan ketahanan pangan di masa depan.

Penelitian [7], membandingkan algoritma *machine learning* untuk memprediksi hasil panen tanaman pangan di Sumatera, meliputi padi, jagung, kacang tanah, kedelai, ubi kayu, dan ubi jalar. Data dari Badan Pusat Statistik (BPS) dan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) digunakan untuk membangun model prediksi menggunakan algoritma *Random Forest*, *Decision Tree*, *Gradient Boosting*, *Extra Tree*, *Support Vector Machine* (SVM), dan *Artificial Neural Network* (ANN). Hasil evaluasi menunjukkan algoritma *Extra Tree* memiliki performa terbaik, dengan nilai koefisien determinasi (R^2) tertinggi sebesar 0,968 untuk prediksi padi dan 0,913 untuk tanaman pangan lainnya. Penelitian ini menyimpulkan bahwa luas panen merupakan variabel yang paling memengaruhi hasil prediksi. Algoritma *Extra Tree* direkomendasikan untuk memprediksi hasil pertanian di wilayah Sumatera, mengingat akurasinya yang lebih tinggi dibandingkan model lainnya.

Penelitian [8], menggunakan teknik *data mining* dengan algoritma *Decision Tree C4.5* untuk memprediksi hasil produksi karet di PT. Perkebunan Nusantara VII, Lampung Selatan. Faktor-faktor yang digunakan dalam prediksi meliputi luas areal, jenis pohon karet, sistem sadap, tahun tanam, dan jumlah pohon. Data produksi dari tahun 2010-2015 dikumpulkan melalui wawancara, observasi, dan dokumentasi. Pengujian prediksi dilakukan menggunakan aplikasi Weka dengan data training sebanyak 1003 record dan diuji menggunakan *10-fold cross-validation*. Hasil penelitian menunjukkan tingkat akurasi 99,90%, dengan klasifikasi data yang mencapai 709 produksi tercapai dan 192 produksi tidak tercapai. Penelitian ini memberikan solusi prediksi yang akurat dan mudah diinterpretasikan, yang dapat digunakan untuk perencanaan produksi karet di masa depan.

Kemudian penelitian oleh [9] mengembangkan sistem prediksi hasil produksi jagung menggunakan algoritma *Decision Tree C4.5*, bertujuan untuk membantu petani dan pemangku kepentingan dalam perencanaan produksi yang lebih efisien. Data yang digunakan berasal dari Kaggle, terdiri dari 4.121 data dari berbagai negara. Proses pengembangan melibatkan tahap *preprocessing*, normalisasi, serta pembagian data latih (80%) dan data uji (20%). Algoritma C4.5 dipilih karena mampu menangani atribut kontinu dan kategorikal, menghasilkan model pohon keputusan yang mudah dipahami. Hasil pengujian menunjukkan akurasi prediksi sebesar 92,82% dibandingkan dengan algoritma *Random Forest* dan KNN, di mana C4.5 memberikan akurasi tertinggi. Penggunaan algoritma ini dinilai efektif dalam menangani kompleksitas data dan meningkatkan kecepatan proses prediksi, dengan variabel seperti kondisi cuaca dan jenis tanah yang memberikan kontribusi signifikan terhadap akurasi.

Penelitian oleh [10] mengaplikasikan algoritma *Support Vector Machine* (SVM) untuk memprediksi hasil panen pertanian salak di Tapanuli Selatan, menggunakan data dari Dinas Pertanian setempat untuk tahun 2019-2020. Dataset terdiri dari atribut kecamatan, luas lahan, dan hasil panen yang diolah melalui *preprocessing*, termasuk cleaning dan normalisasi data. Setelah diterapkan algoritma SVM, hasil prediksi menunjukkan akurasi sebesar 44% dan Root Mean Square Error (RMSE) sebesar 1,49. Penelitian ini memberikan wawasan penting bagi perencanaan produksi pertanian salak, meskipun akurasinya masih dapat ditingkatkan dengan pengembangan lebih lanjut. Sistem ini diharapkan dapat membantu petani dalam memprediksi hasil panen secara lebih efektif, khususnya dalam menghadapi perubahan variabel seperti luas lahan dan jumlah tanaman.

Penelitian relevan lainnya seperti yang dilakukan oleh [11]. Penelitian ini membandingkan algoritma XGBoost dan *Random Forest* untuk klasifikasi data kesehatan mental, menggunakan dataset dari Kaggle dengan 292.364 baris dan 17 fitur. Tahapan *preprocessing* meliputi penanganan missing values, *encoding*, balancing data dengan SMOTE, dan normalisasi dengan MinMaxScaler. Kedua model diuji 30 kali, menghasilkan rata-rata akurasi, presisi, *recall*, dan *F1-Score* sebesar 99.82% untuk XGBoost dan 99.04% untuk *Random Forest*. XGBoost menunjukkan performa lebih unggul, terutama dalam hal akurasi dan efisiensi, berkat penggunaan teknik regularisasi yang efektif mengurangi overfitting. Kesimpulannya, XGBoost lebih baik dalam klasifikasi data kesehatan mental dibandingkan *Random Forest*, dan disarankan untuk digunakan pada aplikasi klasifikasi lainnya yang membutuhkan akurasi tinggi dengan data yang kompleks.

Kemudian penelitian oleh [12]. Penelitian ini mengeksplorasi optimasi klusterisasi untuk lama tempo pekerjaan menggunakan *Gradient Boosting Algorithm* (GBA). Data yang digunakan mencakup variabel seperti job title, kategori pekerjaan, dan jenis kontrak. GBA diterapkan untuk mengelompokkan data dengan akurasi 96%, terutama berhasil dalam mengklasifikasikan jenis pekerjaan *Full-time* dan *Part-time*, namun kesulitan pada kelas Contract/Temp. Penelitian ini juga menggunakan teknik *preprocessing*, seperti Label *Encoding* dan pembagian data untuk melatih model. Hasil evaluasi dengan *confusion matrix* menunjukkan bahwa model mampu mengidentifikasi pola yang baik pada sebagian besar kelas, meskipun masih terdapat tantangan dalam beberapa area. Penelitian ini berkontribusi pada pengembangan manajemen sumber daya manusia dengan menawarkan model yang dapat membantu organisasi membuat keputusan yang lebih baik terkait perencanaan tenaga kerja berdasarkan lama masa kerja.

Penelitian lain yang relevan yaitu pada riset [13] yang membandingkan kinerja berbagai algoritma *machine learning*, seperti *Support Vector Machine* (SVM), *Logistic Regression*, dan *Naive Bayes*, dalam analisis sentimen publik terhadap isu sosial-politik. Hasil penelitian menunjukkan bahwa SVM dan *Logistic Regression* unggul dalam hal *precision* dan *F1-Score*, menjadikannya pilihan yang efektif untuk analisis prediktif berbasis teks. Teknik serupa dapat diadopsi dalam konteks agrikultur untuk memprediksi gagal panen, mengingat kemampuannya dalam menangani data kompleks dan menghasilkan prediksi yang andal.

Penelitian sebelumnya menunjukkan bahwa algoritma C4.5 efektif dalam manajemen persediaan obat di apotek dengan tingkat akurasi mencapai 0,7190. Temuan ini menunjukkan bahwa algoritma ini tidak hanya membantu dalam pengelolaan inventaris, tetapi juga mengurangi risiko kehabisan stok atau overstock [14]. Efektivitas algoritma ini menjadi dasar untuk menerapkannya pada sektor lain, termasuk agrikultur.

Berdasarkan beberapa penelitian sebelumnya, model *machine learning* telah banyak diterapkan untuk memprediksi hasil panen guna mengatasi tantangan ketidakpastian produksi akibat perubahan iklim dan faktor agrikultural. Model-model seperti Regresi Logistik, *Random Forest*, *Extra Tree*, SVM, XGBoost, *Gradient Boosting*, *Decision Tree* C4.5, dan *Naive Bayes* telah menunjukkan performa yang baik dalam berbagai penelitian prediksi hasil pertanian, seperti produksi padi, karet, jagung, dan tanaman pangan lainnya [6] [7] [8] [9] [12] [14]. Studi-studi tersebut menunjukkan bahwa model berbasis pohon (*Extra Tree*, *Random Forest*) dan algoritma Boosting (XGBoost, *Gradient Boosting*) umumnya unggul dalam menangani data kompleks, sementara *Decision Tree* C4.5 dan SVM juga efektif untuk kasus spesifik [9] [10] [11] [13]. Penelitian ini mengkomparasi model-model tersebut untuk menentukan pendekatan terbaik dalam prediksi gagal panen gabah, menggunakan evaluasi metrik seperti akurasi, *F1-Score*, ROC AUC, *precision* dan *recall*. *State of art* penelitian ini adalah penggunaan variabel yang berbeda dan teknik pengujian menggunakan *5-fold cross-validation*.

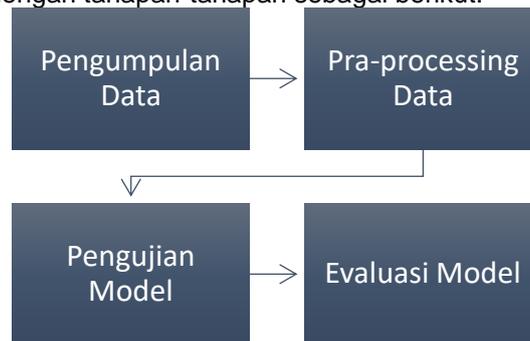
3. Metodologi

3.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk menganalisis kinerja model *machine learning* dalam memprediksi gagal panen gabah. Beberapa algoritma *machine learning* digunakan untuk membandingkan performa prediksi, yaitu: *Naive Bayes*, *Logistic Regression*, *Decision Tree*, *Extra Tree*, *SVM*, *Random Forest*, *XGBoost* dan *Gradient Boosting*. Kinerja model diukur dengan teknik evaluasi *cross-validation* dengan berbagai metrik evaluasi.

3.2 Tahapan Penelitian

Penelitian ini dilakukan dengan tahapan-tahapan sebagai berikut:



Gambar 1. Tahapan Penelitian

3.3 Data Penelitian

Data yang digunakan dalam penelitian ini berasal dari data simulasi terkait faktor-faktor yang mempengaruhi gagal panen gabah di beberapa wilayah. Tabel berikut merangkum variabel-variabel yang digunakan dalam penelitian ini:

Tabel 1. Variabel Penelitian

No	Variabel	Deskripsi
1	Cuaca	Kondisi cuaca (Bagus, Sedang, Buruk)
2	Kelembapan Udara	Kualitas kelembapan udara (Bagus, Sedang, Buruk)
3	Kondisi Tanah	Kualitas kondisi tanah (Bagus, Sedang, Buruk)
4	Variabel Pertanian	Faktor-faktor pertanian (Bagus, Sedang, Buruk)
5	Tungro	Tingkat serangan penyakit Tungro (Bagus, Sedang, Buruk)
6	Gagal Panen	Hasil panen (Y untuk gagal, T untuk berhasil)

Total ada 18 sampel data yang dikategorikan ke dalam dua kelas, yaitu gagal panen (Y) dan tidak gagal panen (T). Sample data sebagai berikut:

Tabel 2. Data Penelitian

No	Wilayah	Cuaca	Kelembapan Udara	Kondisi Tanah	Variabel Pertanian	Tungro	Gagal Panen
1	Aluh-aluh	Bagus	Sedang	Bagus	Buruk	Sedang	Y
2	Beruntung Baru	Sedang	Buruk	Bagus	Buruk	Buruk	Y
3	Gambut	Buruk	Buruk	Buruk	Buruk	Bagus	Y
4	Kertak Hanyar	Sedang	Sedang	Buruk	Buruk	Sedang	Y
5	Tatah Makmur	Sedang	Buruk	Buruk	Sedang	Sedang	Y
6	Sungai Tabuk	Bagus	Bagus	Bagus	Bagus	Sedang	T
7	Martapura	Bagus	Sedang	Bagus	Sedang	Bagus	T
8	Martapura Timur	Bagus	Bagus	Bagus	Bagus	Buruk	T

No	Wilayah	Cuaca	Kelembaban Udara	Kondisi Tanah	Variabel Pertanian	Tungro	Gagal Panen
9	Martapura Barat	Bagus	Sedang	Bagus	Bagus	Bagus	T
10	Astambul	Bagus	Sedang	Sedang	Bagus	Bagus	T
11	Karang Intan	Bagus	Bagus	Bagus	Bagus	Sedang	T
12	Sungai Pinang	Bagus	Bagus	Bagus	Bagus	Bagus	T
13	Pengaron	Bagus	Bagus	Bagus	Sedang	Bagus	T
14	Sambung Makmur	Bagus	Bagus	Bagus	Sedang	Sedang	T
15	Mataraman	Bagus	Bagus	Bagus	Sedang	Sedang	T
16	Simpang Empat	Buruk	Bagus	Bagus	Buruk	Buruk	Y
17	Telaga Bauntung	Bagus	Bagus	Sedang	Bagus	Bagus	T
18	Cintapuri Darussalam	Sedang	Bagus	Sedang	Bagus	Bagus	T

3.4 Preprocessing Data

Sebelum melakukan proses pelatihan model, dilakukan label *encoding* pada variabel-variabel kategorikal untuk mengubah nilai kategorikal menjadi numerik agar dapat diproses oleh algoritma *machine learning*. Setiap variabel seperti "Wilayah", "Cuaca", "Kelembaban Udara", "Kondisi Tanah", "Variabel Pertanian", dan "Tungro" diubah menjadi nilai numerik.

Data dibagi menjadi dua komponen utama:

- Fitur (X): Variabel bebas yang digunakan untuk memprediksi gagal panen (selain variabel "Gagal Panen")
- Target (y): Variabel dependen yaitu "Gagal Panen", yang merupakan hasil klasifikasi dengan dua kelas (Y: Gagal, T: Tidak Gagal).

3.6 Pengujian Model *Machine learning*

Model-model *machine learning* yang digunakan dalam penelitian ini meliputi:

- *Naive Bayes* (GaussianNB)
- *Logistic Regression*
- *Decision Tree*
- *Extra Tree*
- *Support Vector Machine* (SVM) dengan prediksi probabilitas
- *Random Forest*
- XGBoost
- *Gradient Boosting*

Setiap model dipilih berdasarkan kemampuannya dalam menangani masalah klasifikasi biner, dengan fokus pada interpretasi dan performa prediktif dalam konteks agrikultur.

Proses pengujian model dilakukan dalam langkah-langkah berikut:

- 1) Inisialisasi model: Setiap model diinisialisasi dengan parameter default dan kemudian dilatih menggunakan data yang telah disiapkan
- 2) *Cross-validation*: Model dievaluasi menggunakan *5-fold cross-validation*. Pada setiap iterasi, data dibagi menjadi set pelatihan dan set pengujian. *Cross-validation* digunakan untuk memilih model terbaik dari beberapa kandidat dengan mengukur kesalahan prediksi rata-rata pada data yang tidak terlihat. Ini memberikan alternatif yang lebih mudah digunakan dibandingkan dengan pengujian hipotesis nol dan tidak memerlukan banyak asumsi [15] [16].
- 3) Prediksi dan Perhitungan Metrik: Pada setiap *fold*, model melakukan prediksi pada set pengujian, dan metrik evaluasi dihitung untuk akurasi, *precision*, *recall*, *F1-Score*, dan ROC AUC (jika memungkinkan)

- 4) Penggabungan Hasil: Hasil dari setiap fold digabungkan untuk menghitung nilai rata-rata dari setiap metrik, serta *confusion matrix* total untuk setiap model
- 5) Visualisasi: Hasil *confusion matrix* divisualisasikan menggunakan heatmap, dan akurasi model dibandingkan dalam diagram batang untuk memberikan gambaran performa setiap algoritma.

3.7 Evaluasi Model

Untuk mengevaluasi kinerja model, digunakan teknik *Stratified K-Fold Cross-validation* dengan 5 lipatan (*folds*). Teknik ini memastikan bahwa distribusi kelas dalam setiap fold seimbang, mengurangi potensi bias dalam proses evaluasi.

Metrik-metrik evaluasi yang digunakan adalah sebagai berikut:

- *Accuracy*: Mengukur proporsi prediksi yang benar dibandingkan total data.
- *Precision*: Mengukur akurasi prediksi positif model (fokus pada prediksi gagal panen yang tepat).
- *Recall*: Mengukur sensitivitas model dalam mendeteksi kasus gagal panen.
- *F1-Score*: Harmonik rata-rata antara *precision* dan *recall*.
- ROC AUC: Area di bawah kurva ROC yang menunjukkan kemampuan model untuk memisahkan dua kelas (gagal panen vs tidak gagal panen).
- *Confusion matrix*: Menggambarkan hasil klasifikasi dengan menunjukkan jumlah true positive, true negative, false positive, dan false negative.

Setiap model dievaluasi menggunakan metrik-metrik di atas. *Confusion matrix* divisualisasikan menggunakan heatmap untuk melihat seberapa baik model memprediksi kedua kelas (gagal panen dan tidak gagal panen). Selain itu, perbandingan akurasi antar model divisualisasikan dalam bentuk diagram batang (*bar plot*).

4. Hasil dan Pembahasan

4.1 Hasil Pengujian Model Algoritma

Dalam penelitian ini, beberapa algoritma telah diterapkan untuk memprediksi gagal panen gabah berdasarkan data cuaca, kelembapan udara, kondisi tanah, variabel pertanian, dan serangan tungro. Algoritma yang diuji meliputi *Naive Bayes*, *Logistic Regression*, *Decision Tree*, *Extra Tree*, *Support Vector Machine (SVM)*, *Random Forest*, *XGBoost*, dan *Gradient Boosting*. Pengujian dilakukan dengan menggunakan teknik *cross-validation* dan beberapa metrik evaluasi, seperti *accuracy*, *precision*, *recall*, *F1 score*, dan ROC AUC.

Tabel di bawah ini menunjukkan hasil evaluasi dari setiap algoritma:

Tabel 3. Hasil Evaluasi Model

Model	Accuracy	Precision	Recall	F1 Score	ROC AUC
Naive Bayes	0.70	0.80	0.30	0.33	0.80
Logistic Regression	0.63	0.67	0.50	0.43	0.85
Decision Tree	0.65	0.70	0.30	0.30	0.55
Extra Tree	0.67	0.60	0.60	0.47	0.68
SVM	0.60	0.80	0.00	0.00	0.33
Random Forest	0.77	0.80	0.50	0.53	0.73
XGBoost	0.70	0.73	0.80	0.60	0.83
Gradient Boosting	0.70	0.80	0.30	0.33	0.58

4.2 Analisis Performa Model

Hasil analisis performa model adalah sebagai berikut:

- 1) *Naive Bayes* memiliki akurasi sebesar 0.70, dengan *precision* tinggi (0.80), namun *recall*-nya hanya 0.30. *F1 score* sebesar 0.33 menunjukkan bahwa model ini kurang seimbang dalam menangani prediksi positif dan negatif, meskipun AUC ROC menunjukkan hasil yang cukup baik (0.80)
- 2) *Logistic Regression* memberikan akurasi yang lebih rendah (0.63) dibandingkan *Naive Bayes*, namun memiliki *precision* dan *recall* yang seimbang dengan *F1 score* 0.43. Nilai ROC AUC (0.85) menunjukkan bahwa model ini cukup baik dalam mengklasifikasikan secara umum, meski akurasi kurang optimal

- 3) *Decision Tree* menghasilkan akurasi 0.65 dengan *precision* dan *recall* yang rendah, masing-masing 0.70 dan 0.30. *F1 score* yang rendah (0.30) mengindikasikan bahwa model ini memiliki ketidakseimbangan dalam memprediksi hasil positif dan negatif, serta ROC AUC yang relatif rendah (0.55)
- 4) *Extra Tree* memberikan akurasi 0.67 dengan *precision* dan *recall* yang cukup seimbang. Model ini memiliki *F1 score* sebesar 0.47, menunjukkan performa yang lebih baik dibandingkan *Decision Tree*, dengan ROC AUC yang lebih tinggi (0.68)
- 5) SVM menunjukkan hasil yang kurang baik dengan akurasi 0.60 dan *recall* 0.00, yang menyebabkan *F1 score* 0.00. Hal ini menunjukkan bahwa model ini gagal memprediksi kasus gagal panen dengan benar. ROC AUC yang rendah (0.33) mendukung temuan ini
- 6) *Random Forest* memberikan hasil terbaik dengan akurasi 0.77, *precision* 0.80, dan *recall* 0.50, dengan *F1 score* sebesar 0.53. ROC AUC juga menunjukkan hasil yang cukup baik (0.73), menandakan bahwa model ini mampu menangani prediksi gagal panen dengan cukup akurat
- 7) XGBoost memberikan performa yang seimbang dengan akurasi 0.70, *precision* 0.73, dan *recall* 0.80, serta *F1 score* yang cukup tinggi (0.60). Model ini memiliki ROC AUC sebesar 0.83, menunjukkan bahwa XGBoost adalah salah satu model terbaik dalam klasifikasi ini
- 8) *Gradient Boosting* memiliki akurasi 0.70, *precision* yang tinggi (0.80), namun *recall* yang rendah (0.30). Dengan *F1 score* 0.33 dan ROC AUC 0.58, model ini menunjukkan performa yang serupa dengan *Naive Bayes* dalam hal prediksi gagal panen.

4.3 Pembahasan

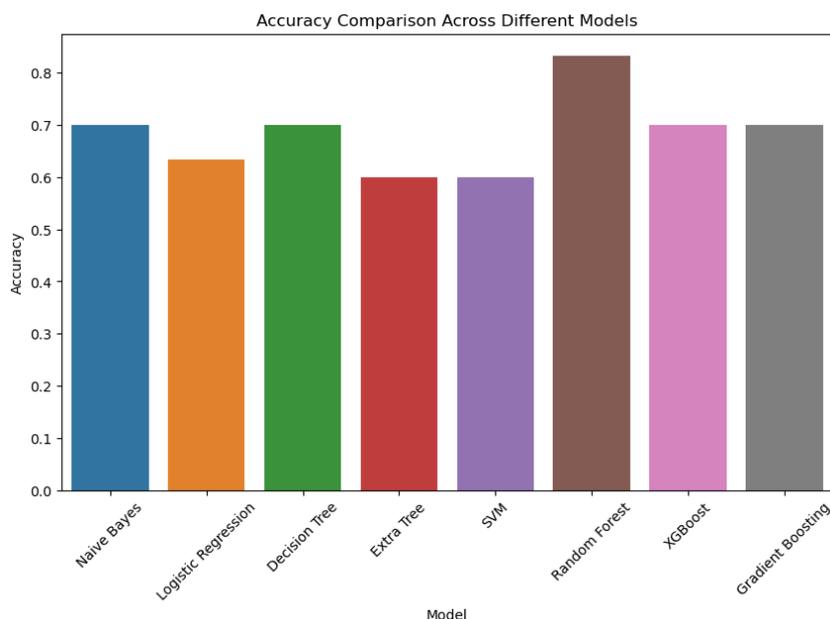
Berdasarkan hasil pengujian, *Random Forest* dan XGBoost terbukti sebagai algoritma yang paling efektif dalam memprediksi gagal panen, hasil ini menguatkan temuan penelitian [11] [12]. Kedua model ini mampu memberikan akurasi yang tinggi, *precision* yang seimbang, serta performa yang kuat berdasarkan nilai *F1 score* dan ROC AUC. *Random Forest* lebih unggul dalam memberikan prediksi yang akurat secara keseluruhan, sementara XGBoost unggul dalam mendeteksi kasus gagal panen yang lebih jarang terjadi (nilai *recall* yang tinggi).

Model SVM tidak mampu memberikan performa yang baik dalam memprediksi gagal panen, mungkin disebabkan oleh kesulitan model dalam menangani dataset yang mungkin memiliki distribusi kelas yang tidak seimbang, serupa dengan hasil penelitian [10] yang hanya menghasilkan akurasi 44%. Untuk model *Naive Bayes* dan *Logistic Regression*, hasil menunjukkan bahwa meskipun keduanya memiliki nilai *precision* yang tinggi, *recall* dan *F1 score*-nya lebih rendah, menunjukkan kelemahan dalam menangani kelas minoritas. Meskipun demikian, algoritma jenis regresi seperti *Logistic Regression* dapat dijadikan model untuk melakukan prediksi gagal panen sebagaimana temuan pada penelitian [6] [13]

Penggunaan metode ensemble seperti *Random Forest* dan *Gradient Boosting* memberikan peningkatan performa yang signifikan dibandingkan dengan metode single *Decision Tree*, seperti yang terlihat pada perbandingan dengan model *Decision Tree* dan *Extra Tree*. Hasil ini berbeda dengan hasil penelitian [7] [8] [9] [14] yang menyimpulkan *Decision Tree* C4.5 lebih akurat dalam melakukan prediksi.

4.4 Visualisasi Hasil

Berikut adalah perbandingan akurasi dari berbagai model yang divisualisasikan dalam bentuk diagram batang berikut:



Gambar 2. Visualisasi Akurasi

5. Simpulan

Penelitian ini menyimpulkan bahwa algoritma *Random Forest* dan *XGBoost* memiliki kinerja terbaik dalam memprediksi gagal panen gabah berdasarkan data cuaca, kelembapan udara, kondisi tanah, variabel agrikultur, dan tingkat serangan penyakit tungro. *Random Forest* unggul dalam memberikan akurasi keseluruhan sebesar 77%, sementara *XGBoost* menunjukkan performa yang kuat dengan *recall* tinggi, menjadikannya lebih efektif dalam mendeteksi kasus gagal panen. Hasil penelitian ini menunjukkan bahwa penerapan *machine learning* dapat menjadi solusi yang andal dalam mendukung pengambilan keputusan di sektor pertanian, khususnya untuk mengurangi risiko gagal panen. Namun, keterbatasan jumlah data dalam penelitian ini menjadi tantangan yang perlu diperhatikan untuk meningkatkan generalisasi model. Penelitian lanjutan disarankan untuk menggunakan dataset yang lebih besar dan mempertimbangkan variabel tambahan, seperti perubahan iklim jangka panjang dan praktik agrikultur lokal, guna menghasilkan prediksi yang lebih akurat dan aplikatif dalam skala yang lebih luas. Dengan pengembangan lebih lanjut, model ini dapat memberikan kontribusi signifikan dalam menciptakan sistem pertanian yang lebih tangguh dan berkelanjutan.

Daftar Referensi

- [1] A. M. Siregar, S. Faisal, Y. Cahyana dan B. Priyatna, "Perbandingan Algoritme Klasifikasi Untuk Prediksi Cuaca," *Jurnal Accounting Information System (AIMS)*, vol. 3, no. 1, pp. 15-24, 2020.
- [2] W. Mulyana, A. Aryanto dan M. Aprilia, "Penerapan Metode Single Exponential Smoothing Untuk Prediksi Kasus Positif COVID 10 di Kabupaten Bengkalis," *Jurnal Computer Science and Information Technology (CoSciTech)*, vol. 3, no. 3, pp. 415-421, 2022.
- [3] S. J. A. B. Bukit dan R. K. R., "Prediksi Harga Tandan Buah Segar dengan Algoritma K-Nearest Neighbor," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 5, no. 1, pp. 92-101, 2023.
- [4] B. Raharjo, *Pembelajaran Mesin (Machine Learning)*, Semarang: Yayasan Prima Agus Teknik, 2021.
- [5] P. Karthikeyan, K. Velswamy, P. Harshavardhanan, R. Rajagopal, V. Jeyakrishnan dan S. Velliangiri, *Machine Learning Techniques Application*, Pennsylvania: IGI Global, 2021.
- [6] M. A. Musababa, "Impelementasi Algoritma Linear Regression untuk Prediksi Produksi Tanaman Padi di Kabupaten Grobogan," *Data Science Indonesia (DSI)*, vol. 3, no. 2, pp. 68-78, 2023.

-
- [7] A. Satria, R. M. Badri dan I. Safitri, "Prediksi Hasil Panen Tanaman Pangan Sumatera dengan Metode Machine Learning," *Digital Transformation Technology (Digitech)*, vol. 3, no. 2, pp. 389-398, 2023.
- [8] N. P. Setyadi, "Penerapan Data Mining Untuk Prediksi Hasil Produksi Karet Menggunakan Algoritma Decision Tree C4.5," *Teknologipintar.org*, vol. 2, no. 7, pp. 1-11, 2022.
- [9] A. Kurnia, W. Witanti dan A. Komarudin, "Sistem Prediksi Hasil Produksi Jagung Menggunakan Algoritma Decision Tree C.45," *Journal Of Informatics And Busisnes*, vol. 02, no. 02, pp. 266-271, 2024.
- [10] R. Kurniawan, A. Halim dan H. Melisa, "Prediksi Hasil Panen Pertanian Salak di Daerah Tapanuli Selatan Menggunakan Algoritma SVM (Support Vector Machine)," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 2, pp. 903-912, 2023.
- [11] K. A. A. W. Wardana dan A. M. A. Rahim, "Analisis Perbandingan Algoritma XGBoost dan Random Forest untuk Klasifikasi Data Kesehatan Mental," *LOGIC: Jurnal Ilmu Komputer dan Pendidikan*, vol. 2, no. 5, 2024.
- [12] F. Septian, "Optimasi Klusterisasi pada Lama Tempo Pekerjaan Berbasis Gradient Boost Algorithm," *Indonesian Journal Of Information Technology (IJITECH)*, vol. 2, no. 1, pp. 1-5, 2024.
- [13] W. Ariannor, S. M. A. B. Alshalwi dan B. Susarianto, "Sentiment Analysis of Netizens on Constitutional Court Rulings in the 2024 Presidential Election," *Indonesian Journal of Informatics Education (IJIE)*, vol. 8, no. 2, pp. 90-100, 2024.
- [14] F. E. Aziz dan D. Abdullah, "Prediksi Persediaan Obat Menggunakan Algoritma Decision Tree (C4.5) Pada Apotek Az-Zikra Bengkulu," *Progresif: Jurnal Ilmiah Komputer*, vol. 20, no. 2, pp. 784-792, 2024.
- [15] M. d. Rooij and W. D. Weeda, "Cross-Validation: A Method Every Psychologist Should Know," *Advances in Methods and Practices in Psychological Science*, vol. 3, no. 2, pp. 248-263, 2020.
- [16] M. Rafał, "Cross validation methods: Analysis based on diagnostics of thyroid cancer metastasis," *ICT Express*, vol. 8, no. 2, pp. 183-188, 2022.