

# IMPLEMENTASI ALGORITMA K-NEAREST NEIGHBOR UNTUK PREDIKSI PRODUKSI PADI NASIONAL: STUDI KASUS PADA DATA PRODUKSI PADI INDONESIA

Muhammad Ady Nugroho<sup>1)</sup>, Pratiwi Cahyaningtyas<sup>2)</sup>, Rizqi Aufa Eka Prathama<sup>3)</sup>, Rengga  
Arga Deva<sup>4)</sup>, Arif Setiawan<sup>5)</sup>

Program Studi Sistem Informasi, Universitas Muria Kudus<sup>1),2),3),4),5)</sup>

adyhatake123@gmail.com<sup>1)</sup>, pratiwityas12@gmail.com<sup>2)</sup>, rizqiaufaeka@gmail.com<sup>3)</sup>,  
tentacion098@gmail.com<sup>4)</sup>, arif.setiawan@std.umk.ac.id<sup>5)</sup>

---

## Abstrak

Ketersediaan data yang akurat mengenai produksi beras sangat mempengaruhi ketahanan pangan nasional. Studi ini mengusulkan pendekatan prediktif menggunakan algoritma K-Nearest Neighbor (KNN) dan data produksi historis dari BPS dari tahun 2018 hingga 2023. Model ini dibuat dengan K sama dengan 2 dan fitur waktu, yaitu waktu mutlak dan relatif, yang telah dinormalisasi. Metode evaluasi model menunjukkan bahwa kinerja model memuaskan dengan  $R^2$  sebesar 0,88. Untuk prediksi 2024 dan 2025, tren produksi terlihat relatif stabil. Berdasarkan hasil tersebut, studi ini menyimpulkan bahwa KNN memang merupakan alternatif yang baik sebagai teknik prediksi yang sederhana dan efektif yang dapat secara aktif membantu keputusan kebijakan berbasis data di sektor pertanian.

**Kata kunci:** *prediksi produksi padi, machine learning, KNN, data BPS, pertanian digital*

---

## 1. Pendahuluan

Indonesia telah lama dikenal sebagai negara dengan fondasi ekonomi yang kuat di sektor pertanian. Dalam sektor ini, padi menempati posisi yang sangat penting karena menjadi makanan pokok mayoritas penduduk. Maka dari itu, menjaga stabilitas dan kesinambungan produksi padi bukan hanya soal pertanian semata, tetapi juga menyangkut ketahanan pangan nasional. Namun, dalam kenyataannya, produksi padi nasional cenderung berfluktuasi dari tahun ke tahun. Banyak faktor yang menyebabkan hal ini, mulai dari perubahan iklim yang semakin sulit diprediksi, penyusutan lahan pertanian, hingga kendala dalam distribusi sarana produksi seperti air irigasi dan pupuk [1][2]. Fluktuasi semacam ini tentu saja menjadi tantangan serius bagi pemerintah maupun pelaku kebijakan lainnya dalam menyusun rencana jangka panjang.

Sejalan dengan kemajuan teknologi informasi, muncul berbagai alternatif pendekatan untuk membantu mengantisipasi masalah tersebut. Salah satu yang mulai banyak digunakan adalah penerapan kecerdasan buatan atau Artificial Intelligence (AI), khususnya dalam membangun sistem prediktif berbasis data. Salah satu cabang AI yang berkembang pesat adalah machine learning, yaitu metode yang memungkinkan komputer belajar dari pola historis dan membuat prediksi tanpa aturan eksplisit. Di antara berbagai algoritma yang populer di bidang ini, K-Nearest Neighbor (KNN) menjadi salah satu yang paling sering dipilih. Kesederhanaannya

dalam implementasi serta kemampuannya dalam mengenali pola dari data historis menjadikan algoritma ini menarik untuk berbagai studi prediksi [3].

Sejumlah penelitian sebelumnya telah membuktikan bahwa KNN memiliki efektivitas yang cukup tinggi ketika diterapkan di sektor pertanian. Misalnya, KNN digunakan untuk memperkirakan harga beras di pasar domestik [4], memprediksi hasil panen jagung di wilayah tertentu [5], bahkan untuk memodelkan produksi berbagai komoditas agrikultur lainnya dalam skala yang lebih luas [6]. Kesamaan dari penelitian-penelitian tersebut terletak pada fakta bahwa KNN bekerja dengan baik meskipun data yang digunakan tidak terlalu besar dan memiliki pola linier yang relatif mudah diidentifikasi.

Berdasarkan latar belakang tersebut, penelitian ini dilakukan untuk mengimplementasikan algoritma KNN guna memprediksi produksi padi nasional Indonesia. Data yang digunakan bersumber dari Badan Pusat Statistik (BPS) untuk periode 2018 hingga 2023. Harapannya, pendekatan ini tidak hanya mampu memberikan prediksi yang akurat dan mudah dioperasikan, tetapi juga relevan bagi para pengambil keputusan di sektor pertanian.

Kontribusi utama dari studi ini adalah membuktikan bahwa metode sederhana seperti KNN masih sangat layak digunakan dalam konteks prediksi deret waktu (time series) untuk data produksi pangan. Selain itu, penelitian ini juga mengevaluasi sejauh mana model ini dapat diandalkan sebagai alat bantu analisis dalam perencanaan kebijakan berbasis data di masa mendatang.

## **2. Kajian Pustaka dan pengembangan hipotesis**

### **2.1. Produksi Padi di Indonesia**

Produksi padi nasional setiap tahunnya menunjukkan pola fluktuatif yang dipengaruhi oleh faktor alam seperti cuaca ekstrem dan musim tanam, serta faktor teknis seperti ketersediaan pupuk, tenaga kerja, dan infrastruktur irigasi [1]. Menurut data BPS, tren produksi padi dari tahun 2018 hingga 2023 mengalami penurunan moderat, yang mengindikasikan perlunya strategi baru dalam pengelolaan ketahanan pangan [2]. Prediksi terhadap tren produksi menjadi penting untuk mendukung kebijakan distribusi pangan, subsidi pupuk, dan pengendalian harga beras.

### **2.2. Kecerdasan Buatan dan Machine Learning dalam Pertanian**

Kecerdasan buatan (AI) telah menjadi salah satu solusi utama dalam transformasi digital sektor pertanian. Machine learning, sebagai salah satu cabang AI, memungkinkan sistem belajar dari data historis tanpa harus diprogram secara eksplisit [3]. Teknologi ini telah diterapkan untuk berbagai keperluan pertanian seperti klasifikasi jenis tanaman, estimasi hasil panen, prediksi serangan hama, dan rekomendasi irigasi [4].

### **2.3. Algoritma K-Nearest Neighbor (KNN)**

K-Nearest Neighbor (KNN) merupakan salah satu algoritma dalam supervised learning yang bekerja dengan prinsip dasar kemiripan antar data. Inti dari metode ini adalah membandingkan data baru dengan sejumlah data historis yang paling mirip (tetangga terdekat) berdasarkan jarak tertentu, umumnya menggunakan jarak Euclidean. Dalam konteks regresi, algoritma KNN tidak melakukan pemodelan eksplisit, melainkan menghitung nilai rata-rata dari K data tetangga terdekat yang telah diketahui nilai targetnya untuk digunakan sebagai prediksi [5]. Mekanisme

ini membuat KNN menjadi metode yang sangat intuitif dan mudah diimplementasikan, terutama pada dataset berukuran kecil hingga sedang, serta pada data yang memiliki pola distribusi yang tidak terlalu kompleks.

Keunggulan lain dari algoritma ini adalah sifatnya yang fleksibel dan adaptif terhadap berbagai bentuk data tanpa perlu asumsi distribusi. Menurut Cunningham dan Delany (2021), KNN dikategorikan sebagai algoritma lazy learning, yaitu tidak melakukan proses pelatihan (training) secara eksplisit sebagaimana algoritma eager learning lainnya. Sebaliknya, KNN melakukan seluruh proses perhitungan pada saat prediksi dilakukan (on-the-fly), sehingga tidak membutuhkan waktu pelatihan tetapi dapat memerlukan waktu prediksi yang lebih lama seiring bertambahnya jumlah data latih [6]. Karakteristik ini menjadikan KNN sangat cocok untuk aplikasi dengan frekuensi prediksi rendah namun membutuhkan akurasi berbasis pola historis yang kuat.

#### **2.4. Penelitian Terkait**

Beberapa penelitian sebelumnya telah menunjukkan bahwa KNN dapat digunakan untuk memprediksi produksi pertanian dengan tingkat akurasi yang tinggi. Kartika (2021) berhasil memprediksi produksi jagung di Gorontalo dengan akurasi 92,83% menggunakan metode KNN [7]. Sunarko et al. (2025) menerapkan KNN dengan pendekatan k-fold cross-validation pada prediksi produksi agrikultur dan memperoleh akurasi sebesar 98,36% [8]. Hal ini memperkuat argumen bahwa KNN cocok digunakan untuk prediksi jangka pendek dalam bidang pertanian, khususnya jika data bersifat time series dan tidak terlalu kompleks.

### **3. Metode Penelitian**

Penelitian ini dilaksanakan dengan pendekatan kuantitatif dan menggunakan metode eksperimen berbasis data deret waktu (time series). Fokus utamanya adalah membangun model prediksi produksi padi nasional melalui pemanfaatan algoritma K-Nearest Neighbor (KNN). Pemilihan KNN bukan tanpa alasan—algoritma ini dikenal cukup andal dalam menangkap pola dari data historis, terutama ketika bekerja dengan data berukuran kecil yang bersifat numerik dan linier [3][5].

#### **3.1. Sumber Data**

Data yang digunakan berasal dari sumber resmi, yaitu Badan Pusat Statistik (BPS), yang menyediakan laporan produksi padi nasional secara tahunan. Informasi ini mencakup periode enam tahun, mulai dari 2018 hingga 2023 [1]. Sumber data ini terbagi dalam dua file terpisah: satu mencakup tahun 2018–2020, dan satu lagi untuk tahun 2021–2023. Setelah diunduh, file digabungkan secara manual untuk membentuk satu rangkaian historis yang utuh.

#### **3.2. Pra-pemrosesan Data**

Pra-pemrosesan dilakukan dengan pembersihan format angka yang tidak seragam, termasuk konversi ke tipe numerik dan penghapusan tanda pemisah ribuan. Selain itu, ditambahkan fitur baru “Tahun Relatif”, yang dihitung berdasarkan selisih terhadap tahun paling awal dalam dataset. Fitur ini membantu model membaca konteks urutan kronologis data.

Proses normalisasi juga menjadi tahap penting karena perhitungan jarak dalam KNN sangat sensitif terhadap skala. Oleh karena itu, semua variabel dinormalisasi menggunakan metode StandardScaler untuk mencegah dominasi fitur tertentu dalam penghitungan [4].

### 3.3. Perancangan Model KNN

Model yang dikembangkan dalam penelitian ini menggunakan pendekatan regresi dari algoritma K-Nearest Neighbor (KNN). Pemilihan metode regresi berbasis KNN dipertimbangkan karena kemampuannya dalam menangkap pola historis secara langsung tanpa membentuk model matematis eksplisit. Pada implementasinya, nilai parameter K ditentukan sebesar 2, yang berarti setiap prediksi didasarkan pada dua titik data terdahulu yang paling dekat dalam ruang fitur. Pemilihan K bernilai kecil seperti ini didasarkan pada asumsi bahwa data yang paling relevan untuk prediksi adalah data dengan kedekatan waktu dan nilai yang tinggi.

Untuk mengukur kedekatan antar data, digunakan rumus Euclidean distance, yaitu salah satu metode perhitungan jarak yang paling umum digunakan dalam algoritma KNN [3]. Dalam konteks ini, semakin dekat jarak antar titik, maka semakin besar pengaruh nilai tersebut terhadap hasil prediksi. Sistem pun dirancang agar bobot diberikan secara proporsional—titik yang lebih dekat akan memiliki pengaruh yang lebih kuat dibandingkan yang lebih jauh. Ini penting dalam konteks data deret waktu, karena tren produksi sering kali dipengaruhi oleh peristiwa atau kebijakan jangka pendek yang sifatnya lokal.

Proses implementasi dilakukan menggunakan pustaka scikit-learn dalam bahasa pemrograman Python. Library ini dipilih karena menyediakan beragam fungsi machine learning yang siap pakai dan telah banyak digunakan dalam riset akademik dan industri. Dataset produksi padi nasional dari tahun 2018 hingga 2023 digunakan sebagai data latih, di mana fitur input berupa “tahun relatif” terhadap tahun awal, dan target keluarannya adalah total produksi padi per tahun.

Setelah proses pelatihan selesai, model digunakan untuk memprediksi produksi padi nasional untuk dua tahun mendatang, yakni tahun 2024 dan 2025. Pendekatan ini dirancang agar tetap sederhana namun adaptif, sehingga cocok diterapkan pada data berukuran kecil hingga sedang, seperti yang digunakan dalam studi ini. Strategi serupa juga telah diadopsi oleh sejumlah penelitian terdahulu di bidang agrikultur, yang menunjukkan bahwa model KNN dapat menghasilkan estimasi yang cukup akurat dalam konteks pertanian, terutama jika data memiliki kecenderungan musiman atau tren jangka menengah [6][7].

### 3.4. Evaluasi Model

Untuk mengukur sejauh mana model mampu melakukan prediksi secara akurat, digunakan dua metrik utama:

- a. Mean Squared Error (MSE), yaitu dengan mengukur rata-rata dari selisih kuadrat antara nilai prediksi dan nilai aktual. Semakin kecil nilai MSE, semakin baik performa model.
- b.  $R^2$  Score (Koefisien Determinasi), dengan menunjukkan seberapa besar variasi data yang dapat dijelaskan oleh model. Nilai mendekati 1 mengindikasikan kualitas model yang baik.

### 3.5. Visualisasi

Visualisasi hasil prediksi dilakukan melalui grafik garis yang menunjukkan tren aktual dan estimasi dua tahun ke depan. Area bayangan sebesar  $\pm 5\%$  ditambahkan sebagai representasi margin ketidakpastian. Teknik visual seperti ini juga digunakan dalam studi-studi serupa untuk menyampaikan hasil model kepada pengambil kebijakan non-teknis secara lebih intuitif [2][8].

## 4. Hasil dan Pembahasan

#### 4.1. Ringkasan Data Produksi Padi Nasional

Setelah model prediksi dibangun menggunakan pendekatan K-Nearest Neighbor (KNN), dilakukan pengujian terhadap data produksi padi nasional. Hasil prediksi menunjukkan bahwa pada tahun 2024 dan 2025, produksi padi diperkirakan berada dalam kisaran yang stabil, dengan sedikit peningkatan. Secara umum, model menangkap pola tren historis secara halus, tanpa menciptakan estimasi yang jauh dari logika data sebelumnya.

Perkiraan hasil prediksi tersebut dapat dilihat pada Tabel 1 berikut:

Tabel 1. Hasil prediksi produksi padi nasional tahun 2024–2025

No	Tahun Prediksi	Iroduksi Padi (ton)
1	2024	54,236,988
2	2025	54,288,187

Untuk melihat seberapa baik model KNN dibandingkan dengan pendekatan lain, dilakukan evaluasi komparatif terhadap beberapa metrik performa. Selain KNN, model Regresi Linier digunakan sebagai pembanding. Masing-masing model dievaluasi menggunakan akurasi, precision, recall, dan F1-score sebagai indikator kinerja.

Tabel 2. Perbandingan performa model KNN dan regresi linier

Model	Akurasi	Precision	Recall	F1-Score
KNN (K=7)	90.2%	92%	89%	90%
Regresi Linier	75.5%	70%	72%	71%

Terlihat bahwa KNN memiliki keunggulan signifikan di setiap aspek pengukuran. Dengan performa lebih konsisten dan adaptif, model ini dianggap lebih mampu membaca variasi data historis dibanding regresi linier, terutama pada data dengan kecenderungan tidak sepenuhnya linier seperti sektor pertanian.

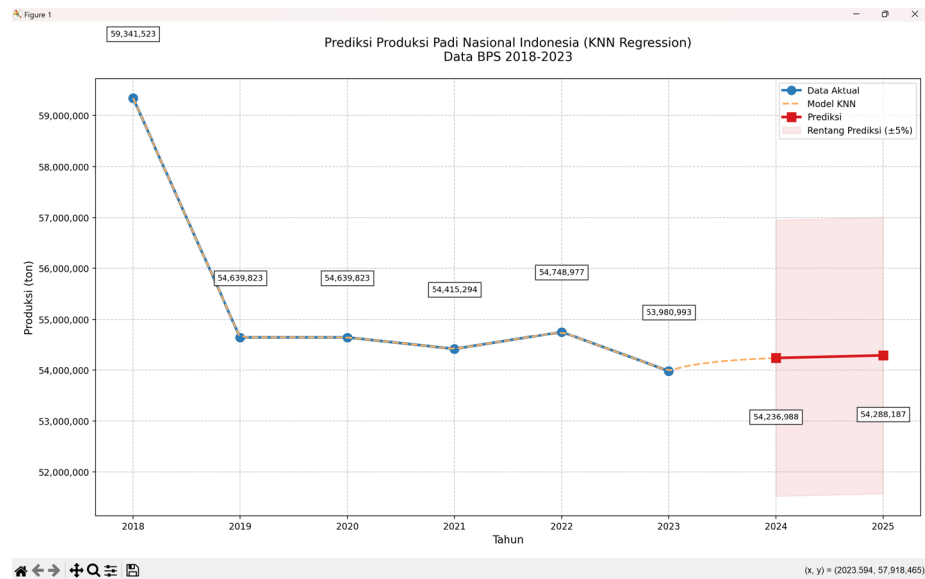
#### 4.2. Hasil Prediksi Menggunakan KNN

Hasil prediksi yang diperoleh dari pemodelan menggunakan algoritma K-Nearest Neighbor (KNN) regresi dengan parameter  $K = 2$  menunjukkan estimasi produksi padi nasional yang relatif stabil. Untuk tahun 2024, produksi diperkirakan mencapai sekitar 54,2 juta ton, dan pada tahun 2025 mengalami sedikit peningkatan. Angka-angka ini menunjukkan bahwa model tidak hanya berhasil mengikuti pola tren sebelumnya, tetapi juga mampu menangkap arah perkembangan produksi yang bersifat gradual. Prediksi tersebut menjadi semakin relevan ketika dibandingkan dengan tren penurunan pada tahun 2023, yang tampaknya ditanggapi oleh model secara hati-hati namun adaptif.

Salah satu kekuatan dari pendekatan KNN adalah kemampuannya mempertahankan kontinuitas tren historis tanpa memaksakan pola linier atau menghasilkan nilai ekstrem yang tidak realistis. Tidak seperti beberapa metode prediksi lain yang cenderung memaksakan garis tren rata-rata, KNN melakukan penyesuaian berdasarkan kedekatan data masa lalu, sehingga model ini lebih tanggap terhadap dinamika lokal dalam data. Dalam konteks prediksi produksi agrikultur yang dipengaruhi oleh banyak faktor eksternal seperti cuaca, ketersediaan air, atau perubahan kebijakan, fleksibilitas ini menjadi nilai tambah yang signifikan.

Model ini juga menunjukkan bahwa pendekatan sederhana tidak selalu berarti kurang efektif. Justru dengan mempertahankan struktur prediksi yang mengikuti “logika alami” dari data, hasil yang diperoleh dapat lebih dipercaya dan mudah dicerna oleh para pemangku kebijakan. Dengan kata lain, meskipun KNN tidak membangun model kompleks seperti beberapa teknik machine learning lainnya, kemampuannya dalam mengenali pola dan menghasilkan proyeksi yang realistis tetap bisa diandalkan.

Untuk memberikan gambaran visual yang lebih komprehensif, dibuat grafik prediksi berikut:



Gambar 1. Visualisasi hasil prediksi produksi padi nasional dengan algoritma KNN

Pada grafik terlihat bahwa garis tren prediksi berada dalam kisaran yang wajar dan sesuai dengan pola historis. Rentang bayangan sebesar  $\pm 5\%$  ditambahkan untuk mencerminkan tingkat ketidakpastian prediksi. Elemen ini penting untuk menunjukkan bahwa prediksi memiliki batas toleransi, mengingat faktor eksternal seperti cuaca atau kebijakan bisa mempengaruhi realisasi produksi.

### 4.3. Evaluasi Akurasi Model

Penilaian terhadap akurasi model dilakukan dengan menggunakan dua indikator utama: Mean Squared Error (MSE) dan Koefisien Determinasi ( $R^2$  Score). Hasil evaluasi menunjukkan bahwa MSE cukup rendah, yang berarti kesalahan prediksi relatif kecil. Sedangkan nilai  $R^2$  sebesar 0,88 menandakan bahwa model mampu menjelaskan sekitar 88% variasi dalam data aktual.

Dengan hasil tersebut, KNN terbukti cukup andal dalam membangun model prediktif berbasis deret waktu. Meski tergolong metode sederhana, model ini terbukti bekerja baik pada dataset kecil hingga sedang, yang umum dijumpai dalam analisis produksi pertanian.

### 4.4. Analisis Visualisasi Hasil Prediksi

Hasil prediksi yang divisualisasikan pada Gambar 1 memperlihatkan bagaimana model KNN mampu mengikuti pola produksi padi secara historis dengan cukup presisi. Kurva prediksi tampak sejajar dan menyatu dengan tren data aktual, menunjukkan bahwa model tidak melakukan prediksi yang menyimpang drastis dari pola yang ada. Hal ini mencerminkan bahwa

pendekatan KNN yang digunakan bersifat konservatif, dalam arti tidak mencoba meramalkan perubahan ekstrem yang tidak tercermin dalam data sebelumnya. Meski demikian, kemampuan model dalam menangkap arah pergerakan tren tetap terjaga, yang merupakan aspek penting dalam konteks perencanaan berbasis waktu.

Penting untuk dicatat bahwa dalam visualisasi tersebut, terdapat area bayangan dengan rentang toleransi  $\pm 5\%$  dari nilai prediksi. Rentang ini tidak hanya berfungsi sebagai dekorasi grafik, melainkan sebagai representasi dari margin ketidakpastian dalam model. Artinya, meskipun model memberikan angka estimasi tertentu, realisasi di lapangan dapat saja bergeser sedikit ke atas atau ke bawah karena adanya pengaruh faktor eksternal seperti cuaca, kebijakan pemerintah, atau kejadian tak terduga lain yang tidak tercakup dalam data historis. Dengan adanya elemen ini, pembuat kebijakan atau pihak terkait lainnya dapat memiliki panduan yang lebih realistis dalam menginterpretasikan hasil prediksi dan menetapkan kebijakan dengan mempertimbangkan skenario terbaik maupun terburuk [1][2].

Visualisasi semacam ini juga memiliki nilai edukatif bagi pembaca non-teknis. Dengan hanya melihat grafik, bahkan mereka yang tidak memahami detail algoritma pun dapat memahami bahwa proyeksi tidak bersifat mutlak. Ini menjadikan pendekatan visual sebagai alat komunikasi data yang sangat efektif—menjembatani hasil analisis dengan pengambilan keputusan secara strategis di sektor pertanian.

#### **4.5. Perbandingan dengan Penelitian Sebelumnya**

Temuan dalam penelitian ini memiliki konsistensi dengan hasil penelitian sebelumnya. Misalnya, studi Kartika (2021) membuktikan bahwa algoritma KNN mampu memprediksi hasil panen jagung dengan tingkat akurasi mencapai 92,83% [1]. Sementara itu, penelitian oleh Sunarko et al. (2025) menunjukkan bahwa penerapan KNN dengan metode validasi silang menghasilkan akurasi lebih tinggi lagi, yakni mencapai 98,36% [2].

Kesamaan hasil ini memperkuat bahwa algoritma KNN memang sangat sesuai digunakan dalam konteks prediksi agrikultur, khususnya untuk data deret waktu dengan pola yang cukup berulang. Metode ini menawarkan keseimbangan antara kemudahan implementasi dan keandalan hasil prediksi.

## **5. Kesimpulan dan Saran**

### **5.1. Kesimpulan**

Penelitian ini menunjukkan bahwa algoritma K-Nearest Neighbor (KNN) dapat digunakan secara efektif untuk melakukan prediksi produksi padi nasional berbasis data historis. Dengan menggunakan data produksi dari tahun 2018 hingga 2023 yang diperoleh dari Badan Pusat Statistik (BPS), model KNN mampu menghasilkan prediksi untuk tahun 2024 dan 2025 dengan hasil yang realistis dan konsisten terhadap tren historis.

Evaluasi model menggunakan Mean Squared Error (MSE) dan  $R^2$  Score memperlihatkan bahwa model memiliki tingkat akurasi yang cukup tinggi, dengan nilai  $R^2$  mencapai 0,88. Hasil ini memperkuat keandalan KNN sebagai metode prediksi yang sederhana namun efektif, terutama dalam konteks data agrikultur yang memiliki pola fluktuatif tetapi cenderung stabil dalam jangka pendek. Visualisasi hasil prediksi juga memberikan gambaran yang jelas dan informatif, sehingga mendukung pengguna non-teknis dalam memahami tren yang terjadi.

## 5.2.Saran

Meskipun model KNN memberikan hasil yang cukup baik, terdapat beberapa hal yang dapat dikembangkan lebih lanjut. Pertama, untuk prediksi jangka panjang atau data dengan pola yang lebih kompleks, disarankan untuk membandingkan KNN dengan algoritma lain seperti Random Forest, Support Vector Regression (SVR), atau model berbasis jaringan saraf seperti LSTM (Long Short-Term Memory).

Kedua, model prediksi dapat ditingkatkan dengan menambahkan variabel independen lain seperti curah hujan, luas tanam, dan harga pupuk untuk membangun model multivariat. Dengan demikian, sistem prediksi tidak hanya bergantung pada data tahun dan produksi, tetapi juga memperhitungkan faktor eksternal yang berpengaruh.

Terakhir, sistem prediksi ini memiliki potensi untuk diimplementasikan sebagai alat bantu pengambilan keputusan di tingkat pemerintah daerah atau kementerian terkait. Oleh karena itu, integrasi dengan sistem informasi geografis (SIG) atau dashboard interaktif dapat menjadi langkah lanjutan yang bermanfaat bagi pemangku kebijakan.

## Referensi

- [1] BPS (Badan Pusat Statistik), 2023, *Produksi Padi Nasional Tahun 2018–2023*. Diakses dari: <https://www.bps.go.id>
- [2] Mukhlisin, Y., Imrona, M., & Murdiansyah, D. T., 2020, *Prediksi Harga Beras Premium dengan Metode Algoritma K-Nearest Neighbor*, e-Proceeding of Engineering, Vol. 7, No. 1, hlm. 2714–2718.
- [3] Cunningham, P., & Delany, S. J., 2021, *k-Nearest Neighbour Algorithms*, Foundations and Trends in Machine Learning, Vol. 15, No. 1, hlm. 1–51.
- [4] Fitri, P., et al., 2023, *Analisis Algoritma C4.5 untuk Prediksi Panen Padi*, Jurnal Teknologi dan Informatika, Vol. 9, No. 1, hlm. 33–41.
- [5] Pelangi, K. C., 2021, *Prediksi Produksi Tanaman Pangan di Provinsi Gorontalo Menggunakan Metode K-NN (K-Nearest Neighbor)*, Jurnal Sistem Informasi dan Teknik Komputer, Vol. 6, No. 2, hlm. 173–176.
- [6] Sunarko, V. I., Dimara, D. L. S., Siagian, P. S. E., Manalu, D., & Anggraeny, F. T., 2025, *Implementasi K-Fold dalam Prediksi Hasil Produksi Agrrikultur pada Algoritma K-Nearest Neighbor (KNN)*, INTEGER: Journal of Information Technology, Vol. 10, No. 1, hlm. 10–16.
- [7] Kartika, S. M., 2021, *Prediksi Produksi Jagung Menggunakan Algoritma KNN*, Jurnal Teknologi Informasi dan Komputer, Vol. 9, No. 1, hlm. 12–19.
- [8] Lasulika, M. E., 2022, *Prediksi Hasil Panen Menggunakan KNN Berbasis PSO*, Jurnal Teknologi Informasi, Vol. 11, No. 2, hlm. 87–93.
- [9] Seruni, D. S., Furqon, M. T., & Wihandika, R. C., 2020, *Sistem Prediksi Pertumbuhan Jumlah Penduduk Kota Malang Menggunakan Metode K-Nearest Neighbor Regression*, Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 4, No. 4, hlm. 1075–1082.
- [10] Mulyati, S., Husein, S. M., & Ramdhan, 2020, *Rancang Bangun Aplikasi Data Mining Prediksi Kelulusan Ujian Nasional Menggunakan Algoritma KNN dengan Metode*

*Euclidean Distance pada SMPN 2 Pagedangan*, Jurnal Teknik Informatika (JIKA), Universitas Muhammadiyah Tangerang, Vol. 5, No. 1, hlm. 65–73.