



## Klasifikasi Jenis Pupuk yang Tepat Berdasarkan Jenis Tanaman dan Kondisi Lahan Menggunakan Random Forest

Ayu Utari Nasution<sup>1</sup>, P.P.P.A.N.W.Fikrul Ilmi R.H.Zer<sup>2</sup>

<sup>1</sup>Teknik Informatika, STIKOM Tunas Bangsa, Pematangsiantar

<sup>2</sup>Manajemen Informatika, STIKOM Tunas Bangsa, Pematangsiantar

E-Mail : [ayuutarinasution01@gmail.com](mailto:ayuutarinasution01@gmail.com), [fikrul@amiktunasbangsa.ac.id](mailto:fikrul@amiktunasbangsa.ac.id)

### Article Info

#### Article history:

Received

Revised

Accepted

#### Kata Kunci:

Klasifikasi Pupuk

Random Forest

Kondisi Lahan

Pertanian Presisi

Data Mining

#### Keywords:

Fertilizer Classification

Random Forest

Soil Conditions

Precision Agriculture

Data Mining

### ABSTRAK

Penelitian ini bertujuan untuk mengembangkan model berbasis Random Forest untuk memberikan rekomendasi jenis pupuk yang tepat berdasarkan kondisi tanah dan jenis tanaman. Data yang digunakan mencakup informasi tentang pH tanah, kelembapan, tekstur tanah, serta kandungan unsur hara (N, P, K) dan jenis tanaman yang meliputi Jagung, Padi, Kacang Tanah, dan lainnya. Model yang dikembangkan diuji pada dataset yang terdiri dari 600 sampel, dengan 30% digunakan untuk data uji. Hasil penelitian menunjukkan bahwa model Random Forest mencapai akurasi 97,83% dengan precision dan recall yang sangat baik pada sebagian besar kelas. Namun, kesalahan klasifikasi terjadi pada kelas NPK, dengan nilai recall 81,82%, yang mengindikasikan adanya kesulitan model dalam mengklasifikasikan jenis pupuk ini. Meskipun demikian, model ini menunjukkan kinerja yang baik dalam memberikan rekomendasi pupuk yang sesuai, yang dapat membantu petani memilih pupuk yang tepat dan meningkatkan hasil pertanian. Penelitian ini juga menunjukkan bahwa faktor-faktor seperti pH tanah dan jenis tanaman merupakan variabel yang sangat penting dalam menentukan jenis pupuk yang sesuai.

### ABSTRACT

*This research aims to develop a Random Forest-based model to provide recommendations for the appropriate type of fertilizer based on soil conditions and crop types. The data used includes information about soil pH, moisture, soil texture, as well as nutrient content (N, P, K) and crop types including Corn, Rice, Peanut, and others. The developed model was tested on a dataset consisting of 600 samples, with 20% used as test data. The results show that the Random Forest model achieved an accuracy of 97.83% with very good precision and recall for most classes. However, misclassification occurred in the NPK class, with a recall value of 81.82%, indicating the model's difficulty in classifying this fertilizer type. Nevertheless, the model performs well in providing accurate fertilizer recommendations, which can assist farmers in selecting the right fertilizer and improving agricultural yields. This study also highlights that factors such as soil pH and crop type are key variables in determining the appropriate type of fertilizer.*

*This is an open access article under the [CC BY-NC](#) license.*



#### Corresponding Author:

Ayu Utari Nasution,

Teknik Informatika, STIKOM Tunas Bangsa

Jln. Jendral Sudirman Blok A No. 1,2&3 Pematangsiantar, 21127, Sumut, Indonesia

Email: [ayuutarinasution01@gmail.com](mailto:ayuutarinasution01@gmail.com)

## 1. PENDAHULUAN

Pemilihan jenis pupuk yang tepat untuk tanaman merupakan faktor yang sangat menentukan dalam keberhasilan pertanian. Tanah yang subur dan penggunaan pupuk yang sesuai dapat meningkatkan hasil pertanian secara signifikan. Namun, dalam prakteknya, pemilihan pupuk sering dilakukan secara manual oleh petani, berdasarkan pengalaman dan kebiasaan yang ada. Hal ini dapat mengarah pada ketidaktepatan dalam pemilihan jenis pupuk, yang pada gilirannya mengurangi efisiensi penggunaan pupuk dan bahkan dapat merusak kualitas tanah dalam jangka panjang (Goyal & Sharma, 2024).

Keberhasilan pertanian sangat bergantung pada faktor-faktor lingkungan dan karakteristik tanah yang sangat variatif. Beberapa faktor seperti pH tanah, kelembapan tanah, tekstur tanah, serta kandungan unsur hara, yaitu nitrogen (N), fosfor (P), dan kalium (K), memiliki peran yang penting dalam menentukan jenis pupuk yang tepat untuk setiap jenis tanaman. Kondisi tanah yang berbeda-beda mempengaruhi keberhasilan tanaman dan jenis pupuk yang dapat digunakan, dan di sinilah machine learning dapat berperan untuk memberikan solusi yang lebih tepat dan efisien. Penggunaan teknologi dalam menentukan rekomendasi pupuk yang lebih akurat dapat membantu petani dalam meningkatkan hasil pertanian dan mengoptimalkan penggunaan pupuk.

Seiring dengan pesatnya perkembangan teknologi, machine learning muncul sebagai teknologi yang dapat membantu dalam proses analisis dan rekomendasi pupuk yang lebih cerdas. Salah satu metode algoritma yang sangat umum diterapkan dalam machine learning adalah *Random Forest*, yang merupakan algoritma berbasis ensemble learning yang membangun banyak pohon keputusan dan menggabungkan hasilnya untuk memberikan prediksi yang lebih stabil dan akurat (Deshpande & Golegaonkar, 2025). *Random Forest* memiliki kelebihan utama yaitu kemampuannya untuk menangani data yang kompleks dan mempunyai banyak fitur, sehingga cocok untuk aplikasi dalam pertanian yang memerlukan analisis berbagai faktor tanah dan tanaman secara bersamaan (Shingade & Pandit, 2025).

Penelitian terkait penerapan machine learning dalam pertanian, khususnya untuk rekomendasi pupuk, telah banyak dilakukan. Misalnya, penelitian oleh Montañez dan Sarmiento (2024) yang memanfaatkan *machine learning* untuk mendeteksi pH tanah, kandungan makronutrien, dan mikronutrien tanah, serta memberikan rekomendasi pupuk berdasarkan data yang dikumpulkan. Selain itu, penelitian oleh Wetzel & Workman (2025) menunjukkan bahwa penggunaan *Raman Spectroscopy* yang digabungkan dengan *machine learning* dapat memberikan analisis pupuk yang lebih cepat dan efisien.

Namun, meskipun ada banyak penelitian yang telah menggunakan *machine learning* untuk rekomendasi pupuk, penerapan *Random Forest* dalam mengklasifikasikan jenis pupuk yang tepat berdasarkan berbagai faktor yang melibatkan kombinasi tekstur tanah, pH, kelembapan, dan kandungan unsur hara masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem berbasis *Random Forest* yang dapat memberikan rekomendasi pupuk yang tepat dengan mempertimbangkan berbagai kondisi tanah dan tanaman yang lebih beragam, berdasarkan data yang telah dikumpulkan dari daerah pertanian di Indonesia.

Penelitian ini menggunakan data yang mencakup informasi detail mengenai jenis tanaman, tekstur tanah, pH tanah, kelembapan tanah, dan kandungan unsur hara seperti N, P, K. Data tersebut diolah menggunakan *RapidMiner*, sebuah perangkat lunak yang efisien untuk pengolahan data besar serta pembuatan model *machine learning*. Dengan memanfaatkan algoritma *Random Forest*, penelitian ini bertujuan untuk mengklasifikasikan jenis pupuk yang paling sesuai berdasarkan berbagai faktor terkait tanah dan tanaman.

Dengan menggunakan data yang lebih komprehensif dan representatif, penelitian ini bertujuan untuk memberikan solusi yang lebih praktis bagi petani dalam memilih pupuk yang tepat dan efisien, yang pada gilirannya berkontribusi terhadap peningkatan hasil pertanian dan keberlanjutan sektor pertanian itu sendiri.

## 2. METODE PENELITIAN

### 2.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tujuan mengembangkan dan mengevaluasi model klasifikasi jenis pupuk menggunakan algoritma *Random Forest*. Algoritma ini dipilih karena kemampuannya dalam menangani data yang kompleks dan memiliki ketahanan terhadap *overfitting* (Putra & Siregar, 2022). Fokus utama penelitian adalah kemampuan model dalam mengklasifikasikan jenis pupuk yang sesuai berdasarkan faktor agronomis, seperti jenis tanaman, pH tanah, tekstur tanah, kelembapan tanah, dan kandungan unsur hara (Giesen & Jansen, 2020).

Penelitian ini dilakukan dengan menggunakan dataset simulasi yang berjumlah 600 entri. Data tersebut dibagi ke dalam dua bagian, yaitu 70% untuk data pelatihan dan 30% untuk data pengujian. Hasil klasifikasi dievaluasi dengan menggunakan metrik standar, seperti akurasi, *precision*, *recall*, dan *confusion matrix*. (Wijaya & Andayani, 2023).

## 2.2. Data

Data yang digunakan dalam penelitian ini meliputi informasi tentang jenis tanaman, tekstur, pH, kelembaban, dan keberadaan unsur hara (N, P dan K). Dataset ini terdiri dari 600 sampel yang menggambarkan berbagai kondisi tanaman dan tanah yang berasal dari daerah pertanian Indonesia. Variabel yang dibahas meliputi:

- Jenis Tanaman: Jenis tanaman yang dianalisis dalam penelitian ini antara lain Jagung, Kacang Tanah, dan Cabai.
- Tekstur Tanah: Tipe tekstur tanah seperti Lempung, Berpasir, dan Liat.
- pH Tanah: Nilai pH tanah yang mengindikasikan tingkat keasaman tanah.
- Kelembapan Tanah: Persentase kelembapan tanah.
- Kandungan N, P, K: Kandungan unsur hara Nitrogen (N), Fosfor (P), dan Kalium (K).

Dataset ini diperoleh melalui eksperimen lapangan yang dilakukan di berbagai wilayah pertanian Indonesia. Pengumpulan data seperti ini sejalan dengan metodologi yang telah diterapkan dalam penelitian terkait rekomendasi pupuk berbasis *machine learning* di sektor pertanian

## 2.3. Proses Preprocessing Data:


Sebelum data diaplikasikan untuk melatih model *Random Forest*, data harus diproses terlebih dahulu untuk memastikan bahwa data selalu digunakan selalu digunakan dan tidak mengandung informasi yang tidak valid atau salah. Langkah pra-proses ini menyortir beberapa langkah penting:

- Import Data*: Data yang disediakan dalam format CSV diimpor ke dalam perangkat lunak *RapidMiner*, yang digunakan untuk mengolah dan membangun model.
- Pembersihan Data*: Proses ini mencakup Pemeriksaan terhadap data yang tidak lengkap. Dan penggantian nilai yang hilang menggunakan teknik imputasi sederhana, seperti rata-rata atau median. Teknik ini telah dipakai dalam berbagai penelitian yang berfokus pada pengolahan data pertanian.
- Label Encoding*: Variabel kategorikal seperti Jenis Tanaman dan Tekstur Tanah diencoding menggunakan *Label Encoding* untuk mengubah kategori menjadi angka. Teknik ini sudah diterapkan dalam banyak penelitian terkait *machine learning* dalam bidang pertanian.
- Normalisasi*: Variabel numerik, seperti pH Tanah, Kelembapan Tanah, dan kandungan N, P, K, dinormalisasi agar berada dalam rentang yang serupa, sehingga model tidak terpengaruh oleh perbedaan skala antar fitur. Normalisasi ini merupakan langkah penting dalam banyak sistem berbasis *machine learning*, terutama yang digunakan dalam prediksi hasil pertanian.

## 2.4. Pembagian Data:

Data dibagi menjadi dua bagian:

- 70% Data Latih: Diterapkan untuk menguji model *Random Forest*.
- 30% Data Uji: Diterapkan untuk melatih kinerja model yang telah dilatih. Pembagian data ini telah banyak diterapkan dalam penelitian machine learning untuk aplikasi pertanian.



Gambar 1. Pembagian dataset


## 2.5. Pembangunan Model:

Model klasifikasi Random Forest dibangun menggunakan *RapidMiner*. *Random Forest* dipilih karena kemampuannya dalam mengelola data yang kompleks dengan memiliki banyak fitur. Dalam proses pembangunan model ini, beberapa langkah penting diambil:

- Pengaturan Parameter Model*: Beberapa parameter seperti jumlah pohon (*trees*) dan maksimum kedalaman pohon disesuaikan untuk mencapai kinerja terbaik. Pendekatan ini telah digunakan dalam penelitian yang mengembangkan sistem rekomendasi berbasis *machine learning* (Goyal & Sharma, 2024).
- Pelatihan Model*: Data latih diterapkan untuk menguji model *Random Forest*, dengan tujuan agar model dapat mempelajari pola yang ada dalam data terkait dengan prediksi jenis pupuk yang sesuai.

Model *Random Forest* telah terbukti efektif dalam prediksi berbasis data pertanian (Montañez & Sarmiento, 2024).

- c. Pengujian Model: Setelah model dilatih, data pengujian digunakan untuk mengevaluasi akurasi model dalam memprediksi jenis pupuk yang tepat berdasarkan data yang tersedia.



Gambar 2. Parameter utama *Random forest*

## 2.6. Evaluasi Model:


Model dievaluasi menggunakan metrik berikut:

- a. Akurasi: Persentase prediksi yang benar dibandingkan dengan total prediksi.
- b. Precision dan Recall: Mengukur ketepatan dan kemampuan model dalam mengidentifikasi kelas tertentu. Teknik evaluasi ini sudah diterapkan dalam berbagai sistem rekomendasi berbasis *machine learning*.
- c. F1-Score: Harmonisasi rata - rata antara mengingat dan presisi memberikan gambaran tentang hubungan hubungan antara keduanya diantara keduanya. Teknik ini telah digunakan dalam sejumlah penelitian yang menerapkan pembelajaran mesin pada rekomendasi pupuk.
- d. Evaluasi dilakukan dengan menggunakan *cross-validation* untuk memastikan bahwa model dapat digeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

## 3. HASIL DAN PEMBAHASAN

### 3.1. Struktur Alur Proses Pemodelan di *RapidMiner*

Proses pemodelan menggunakan *Random Forest* di *RapidMiner* dimulai dengan pembacaan data dari file CSV dan diikuti dengan penetapan peran atribut untuk proses pelatihan dan pengujian model. Gambar 1 menunjukkan alur proses pemodelan di *RapidMiner*, yang terdiri dari beberapa tahapan: pembacaan dataset, pemisahan data (70% untuk pelatihan dan 30% untuk pengujian), Pelatihan model dengan menggunakan *Random Forest*, serta evaluasi kinerja model.



Gambar 3. Model *Rapidminer Studio*

Setelah data diproses dan model dilatih, operator *Performance* dipakai untuk menilai kinerja model berdasarkan metrik yang sudah ditentukan, seperti akurasi, *precision*, *recall*, dan *F1-Score*. Hasilnya menunjukkan bahwa *Random Forest* memberikan hasil yang sangat baik dalam mengklasifikasikan jenis pupuk berdasarkan data tanah dan tanaman.

### 3.2. Hasil Prediksi Model

Salah satu hasil keluaran prediksi pada data uji ditampilkan pada Gambar 2. Tabel tersebut menunjukkan bahwa sebagian besar klasifikasi sesuai dengan label aktual, terutama untuk pupuk Kompos, NPK, dan ZA. Sebagai contoh, pada baris ke-2, tanaman Jagung diprediksi dengan *confidence* 0.918, yang menunjukkan prediksi yang sangat tepat. Namun, beberapa kesalahan juga terjadi, seperti pada baris ke-5, di mana tanaman Urea diprediksi sebagai Kompos, yang menunjukkan kelemahan model dalam mengidentifikasi pupuk yang sesuai untuk tanaman tertentu.

Tabel di bawah ini memberikan gambaran tentang *confidence* yang dihasilkan oleh model untuk beberapa data uji.

| Row No. | Jenis_Pupuk | prediction(J... | confidence[... | confidence[... | confidence[... | confidence[... | Jenis_Tana... | Tekstur_Ta... | pH_Tanah | Kelembapan... | Kan |
|---------|-------------|-----------------|----------------|----------------|----------------|----------------|---------------|---------------|----------|---------------|-----|
| 1       | Kompos      | Kompos          | 0.023          | 0.918          | 0.028          | 0.032          | Padi          | Lempung       | 7.100    | 66            | 64  |
| 2       | Kompos      | Kompos          | 0.036          | 0.910          | 0.021          | 0.032          | Kacang Tanah  | Gambut        | 6.200    | 53            | 68  |
| 3       | Kompos      | Kompos          | 0.025          | 0.883          | 0.023          | 0.069          | Cabai         | Berpasir      | 6.800    | 75            | 23  |
| 4       | Kompos      | Kompos          | 0.065          | 0.868          | 0.043          | 0.023          | Bawang Merah  | Lempung       | 4.900    | 82            | 88  |
| 5       | Urea        | Urea            | 0.133          | 0.072          | 0.779          | 0.016          | Jagung        | Gambut        | 5.400    | 70            | 76  |
| 6       | Kompos      | Kompos          | 0.026          | 0.881          | 0.023          | 0.070          | Tomat         | Lempung       | 6.900    | 72            | 23  |
| 7       | Kompos      | Kompos          | 0.038          | 0.884          | 0.060          | 0.018          | Kacang Tanah  | Gambut        | 5.200    | 74            | 56  |
| 8       | Kompos      | Kompos          | 0.065          | 0.851          | 0.055          | 0.029          | Padi          | Liat          | 6.700    | 57            | 23  |
| 9       | Kompos      | Kompos          | 0.021          | 0.882          | 0.064          | 0.032          | Jagung        | Lempung       | 7.400    | 43            | 60  |
| 10      | NPK         | NPK             | 0.563          | 0.328          | 0.040          | 0.069          | Cabai         | Berpasir      | 5.300    | 41            | 68  |
| 11      | Kompos      | Kompos          | 0.054          | 0.893          | 0.023          | 0.029          | Kentang       | Gambut        | 7.100    | 84            | 49  |
| 12      | ZA          | ZA              | 0.010          | 0.204          | 0.043          | 0.743          | Tomat         | Liat          | 4.800    | 56            | 118 |
| 13      | Kompos      | Kompos          | 0.039          | 0.907          | 0.021          | 0.032          | Bawang Merah  | Liat          | 6        | 69            | 21  |
| 14      | Kompos      | Kompos          | 0.021          | 0.917          | 0.029          | 0.033          | Padi          | Liat          | 7.100    | 78            | 44  |
| 15      | Kompos      | Kompos          | 0.021          | 0.892          | 0.054          | 0.032          | Jagung        | Gambut        | 7        | 50            | 36  |
| 16      | Urea        | Urea            | 0.008          | 0.206          | 0.768          | 0.018          | Jagung        | Berpasir      | 5.700    | 64            | 28  |

Gambar 4. Hasil model prediksi

Hasil ini menunjukkan bahwa model *Random Forest* memberikan hasil yang sangat baik dalam memprediksi jenis pupuk berdasarkan kondisi tanah dan tanaman. Model berhasil mengenali pola yang ada dalam data, dengan prediksi yang sangat akurat pada sebagian besar kasus. Namun, kesalahan prediksi terjadi pada tanaman yang memiliki kondisi tanah atau jenis pupuk yang lebih spesifik, seperti Padi yang salah diprediksi sebagai Kompos.

### 3.3. Hasil Klasifikasi

Model klasifikasi jenis pupuk menggunakan algoritma *Random Forest* yang diterapkan pada dataset yang berisi 600 entri data menunjukkan akurasi sebesar 97,83%. Dataset ini mencakup data tentang jenis tanaman, tekstur tanah, pH tanah, kelembapan tanah, serta kandungan unsur hara (Nitrogen, Fosfor, Kalium). Model ini berhasil mengklasifikasikan pupuk dengan sangat baik pada sebagian besar kelas, terutama pada Kompos, Urea, dan ZA. Berdasarkan hasil *confusion matrix*, sebagian besar kesalahan klasifikasi terjadi pada NPK, yang diprediksi salah sebagai Kompos.

accuracy: 97.83%


|              | true NPK | true Kompos | true Urea | true ZA | class precision |
|--------------|----------|-------------|-----------|---------|-----------------|
| pred. NPK    | 54       | 0           | 0         | 0       | 100.00%         |
| pred. Kompos | 12       | 409         | 0         | 1       | 96.92%          |
| pred. Urea   | 0        | 0           | 56        | 0       | 100.00%         |
| pred. ZA     | 0        | 0           | 0         | 68      | 100.00%         |
| class recall | 81.82%   | 100.00%     | 100.00%   | 98.55%  |                 |

Gambar 5. Hasil *Confusion Matrix*

Pada *Confusion Matrix* tersebut, dapat dilihat bahwa Kompos dan Urea memiliki *precision* yang sangat tinggi (100%), sementara NPK mengalami sedikit kesalahan klasifikasi. Prediksi NPK sebagian besar jatuh ke kelas Kompos, dengan *precision* NPK sebesar 81,82%.

### 3.4. Visualisasi Pohon Keputusan

Berikut ini adalah gambar Visualisasi Pohon Keputusan dari algoritma Random Forest di RapidMiner:



Gambar 6. Hasil pohon keputusan

Untuk lebih memahami bagaimana model membuat keputusan, berikut adalah visualisasi Pohon Keputusan yang dihasilkan oleh *Random Forest*. Pohon keputusan ini menggambarkan bagaimana model memutuskan klasifikasi berdasarkan fitur input seperti pH tanah, kandungan N, kandungan P, dan jenis tanaman.

Pada pohon keputusan ini, pemisahan pertama terjadi pada nilai pH tanah, diikuti dengan percabangan berdasarkan Kandungan N dan Kandungan P. Misalnya, ketika nilai pH tanah lebih besar dari 6,5, model lebih cenderung memprediksi Kompos, sedangkan untuk Kandungan N yang lebih tinggi, model lebih sering memilih NPK. Fitur Jenis Tanaman juga berperan penting dalam memisahkan kelas, terutama dalam kasus tanaman seperti Jagung dan Padi, yang cenderung diklasifikasikan dengan jenis pupuk yang lebih spesifik.

### 3.5. Evaluasi Model

Hasil evaluasi menunjukkan bahwa model *Random Forest* menghasilkan performa yang sangat baik pada data uji, dengan akurasi sebesar 97,83%. Metrik *precision*, *recall*, dan *F1-score* untuk masing-masing kelas juga menunjukkan hasil yang signifikan. Berikut ini adalah hasil penilaian model berdasarkan metrik evaluasi:

Tabel 1. Hasil Accuracy model

| Kelas  | Precision | Recall | F1-Score |
|--------|-----------|--------|----------|
| Kompos | 100%      | 100%   | 100%     |
| Urea   | 100%      | 100%   | 100%     |
| NPK    | 81,82%    | 100%   | 90,91%   |
| ZA     | 100%      | 98,55% | 99,27%   |

Dari hasil tersebut, Kompos dan Urea terbukti memiliki akurasi yang sangat tinggi, dengan hampir tidak ada kesalahan klasifikasi. Namun, pada NPK, meskipun *recall* menunjukkan 100%, *precision* sedikit lebih rendah karena sebagian besar data NPK diklasifikasikan sebagai Kompos.

### 3.6. Keterbatasan dan Saran Pengembangan

Meskipun model ini menunjukkan kinerja yang sangat baik, terdapat beberapa keterbatasan yang perlu diperhatikan:

- Kesalahan Klasifikasi pada NPK: Model kesulitan dalam membedakan antara NPK dan Kompos, yang disebabkan oleh kurangnya variasi dalam data atau kurangnya fitur pembeda yang kuat. Hal ini menunjukkan bahwa tambahan fitur seperti data iklim atau sensor mikrobiologi tanah dapat meningkatkan akurasi prediksi untuk kelas ini.
- Penggunaan Data Dunia Nyata: Meskipun dataset simulasi memberikan hasil yang memuaskan, pengujian dengan data dunia nyata dapat memberikan pemahaman lebih dalam tentang performa

model di lapangan. Penggunaan data aktual dari petani dapat menambah variasi dan meningkatkan generalisasi model.

- c. Integrasi Teknologi IoT: Untuk mempermudah implementasi dan mempermudah petani, model ini dapat diintegrasikan dengan sistem berbasis *Internet of Things* (IoT) yang memungkinkan pemantauan kondisi tanah secara *real-time*. Hal ini memberikan rekomendasi pemupukan secara langsung berdasarkan kondisi tanah yang terukur.
- d. Aplikasi Mobile: Salah satu langkah pengembangan yang dapat dilakukan adalah mengintegrasikan model ini ke dalam bentuk aplikasi mobile berbasis *Decision Support System* (DSS). Aplikasi ini dapat memberikan rekomendasi pupuk kepada petani dengan berbasis data yang akurat dan mudah diakses.

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi jenis pupuk yang tepat berdasarkan kondisi lahan dan jenis tanaman dengan menggunakan algoritma *Random Forest*. Berdasarkan hasil evaluasi yang dilakukan, model ini mampu mencapai akurasi 97,83%, dengan *precision* dan *recall* yang sangat baik pada sebagian besar kelas. Kelas Kompos, Urea, dan ZA berhasil diprediksi dengan 100% *precision* dan *recall*, menunjukkan bahwa model sangat akurat dalam mengklasifikasikan jenis pupuk tersebut. Namun, kelas NPK mengalami sedikit penurunan performa, dengan *recall* yang lebih rendah (81,82%) akibat beberapa data yang diprediksi sebagai Kompos.

Visualisasi pohon keputusan menunjukkan bahwa fitur-fitur seperti pH tanah, Kandungan N, dan Kandungan P memiliki peran dominan dalam mempengaruhi keputusan klasifikasi. Hal ini menunjukkan bahwa parameter tanah, terutama pH dan kandungan unsur hara, sangat berpengaruh terhadap jenis pupuk yang harus diterapkan pada tanaman tertentu. Hasil ini menunjukkan bahwa algoritma *Random Forest* memiliki potensi yang besar dalam meningkatkan efisiensi pemupukan dalam sektor pertanian, khususnya di Indonesia, di mana penggunaan pupuk yang tidak tepat seringkali menjadi masalah. Model ini memberikan rekomendasi yang lebih presisi dengan mempertimbangkan karakteristik tanah dan tanaman, serta mengurangi ketergantungan pada metode konvensional yang sering kali tidak optimal.

Namun, meskipun model ini memberikan hasil yang sangat baik, terdapat beberapa keterbatasan yang perlu diperbaiki untuk meningkatkan performa lebih lanjut. Kesulitan model dalam membedakan antara NPK dan Kompos menunjukkan adanya potensi untuk menambah fitur tambahan, seperti data cuaca, mikrobiologi tanah, atau bahkan data prediktif berbasis iklim yang dapat memperbaiki kemampuan model dalam menangani variasi yang lebih luas. Selain itu, untuk mengimplementasikan model ini secara praktis, diperlukan pengujian dengan data dunia nyata yang lebih kompleks dan beragam, bukan hanya data simulasi. Hal ini memastikan bahwa model dapat bekerja dengan baik dalam kondisi lapangan yang lebih dinamis.

Integrasi dengan teknologi IoT juga menjadi langkah penting untuk mengoptimalkan aplikasi model ini di lapangan. Dengan menggunakan sensor tanah berbasis IoT, data *real-time* dapat digunakan untuk memberikan rekomendasi pemupukan yang lebih cepat dan sesuai dengan kondisi tanah yang berubah-ubah, sehingga petani dapat memperoleh hasil yang lebih optimal. Akhirnya, untuk meningkatkan aksesibilitas dan kemudahan bagi petani, pengembangan aplikasi *mobile* berbasis *Decision Support System* (DSS) akan menjadi kunci dalam memastikan bahwa teknologi ini diterima dan digunakan dengan efektif. Aplikasi ini dapat memberikan rekomendasi pemupukan secara langsung kepada petani, yang dapat diakses disetiap saat di mana saja, sehingga meningkatkan produktivitas pertanian secara efisien dan berkelanjutan.

Secara keseluruhan, penelitian ini telah membuktikan bahwa *Random Forest* adalah algoritma yang sangat efektif untuk mengklasifikasikan jenis pupuk berdasarkan kondisi lahan dan jenis tanaman, dan dapat diaplikasikan dalam sistem pertanian presisi berbasis data. Dengan pengembangan lebih lanjut, model ini memiliki potensi besar untuk mendukung pertanian berkelanjutan dan efisiensi sumber daya dalam skala yang lebih luas.

#### ACKNOWLEDGEMENTS

Saya mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dalam pelaksanaan penelitian ini. Saya mengucapkan terima kasih kepada dosen pembimbing yang telah memberikan bimbingan dan masukan yang sangat berharga selama proses penelitian ini. Ucapan terima kasih juga disampaikan kepada teman-teman dan keluarga yang senantiasa memberikan dukungan moril serta semangat. Penulis juga mengucapkan terima kasih kepada semua pihak yang tidak dapat saya sebutkan satu per satu atas segala bantuan yang diberikan dalam menyelesaikan penelitian ini.

## REFERENCES

- Deshpande, R., & Golegaonkar, P. (2025). Machine learning platform for agricultural predictions and recommendations. In M. S. Uddin & J. C. Bansal (Eds.), *Proceedings of International Joint Conference on Advances in Computational Intelligence* (pp. 123–134). Springer. [https://doi.org/10.1007/978-981-96-3762-1\\_9](https://doi.org/10.1007/978-981-96-3762-1_9)
- Ding, Y., & Zhang, W. (2023). Quantitative analysis of fertilizer using laser-induced breakdown spectroscopy. *Frontiers in Chemistry*, 11, 1–9. <https://www.frontiersin.org/journals/chemistry/articles/10.3389/fchem.2023.1123003/full>
- Goyal, A., & Sharma, S. (2024). Crop and fertilizer recommendation using machine learning. *International Journal of Novel Research and Development*, 9(4), 1–8. Retrieved from <https://www.ijnrd.org/papers/IJNRD2404212.pdf>
- Haq, I., & Ahmad, S. (2023). Optimizing machine learning models for soil fertility analysis. *DergiPark Journal*, 8(5), 1–10. Retrieved from <https://dergipark.org.tr/en/download/article-file/4459322>
- Lad, S., & Thilakarathne, R. (2022). Comparative analysis of supervised learning methods for crop recommendation. *Engineering Proceedings*, 58, 97. <https://www.researchgate.net/publication/381281441>
- Montañez, J. J., & Sarmiento, J. (2024). Machine learning for the detection of soil pH, macronutrients, and micronutrients with crop and fertilizer recommendations. *International Journal of Artificial Intelligence*, 14(1), 439–446. <https://doi.org/10.11591/ijai.v14.i1.pp439-446>
- Qi, J., & Zhang, T. (2024). Rapid classification of agricultural fertilizers by laser-induced breakdown spectroscopy and random forest. *Spectrochimica Acta Part B: Atomic Spectroscopy*, 149, 288–293. <https://www.sciencedirect.com/science/article/pii/S0584854718301453>
- Reddy, V., & Varshini, V. (2023). Hybrid approaches in crop recommendation systems. *International Journal of Research in Agronomy*, 2(1), 7–11. <https://doi.org/10.46632/eae/2/1/5>
- Reddy, V., & Varshini, V. (2023). Hybrid approaches in crop recommendation systems. *International Journal of Research in Agronomy*, 2(1), 7–11. <https://doi.org/10.46632/eae/2/1/5>
- Rohan, V. N., & Chaitanya, J. (2024). A machine learning-based fertilizer recommendation system for sustainable crop yield. *International Research Journal of Education and Technology*, 6(12), 1777–1785. <https://doi.org/10.46632/irjet/6/12/5>
- Senesi, G. S., & Romano, R. A. (2024). Laser-induced breakdown spectroscopy associated with multivariate analysis applied to discriminate fertilizers of different nature. *Journal of Applied Spectroscopy*, 84(5), 923–928. <https://link.springer.com/article/10.1007/s10812-017-0566-4>
- Senesi, G. S., & Romano, R. A. (2024). Laser-induced breakdown spectroscopy associated with multivariate analysis applied to discriminate fertilizers of different nature. *Journal of Applied Spectroscopy*, 84(5), 923–928. <https://link.springer.com/article/10.1007/s10812-017-0566-4>
- Shingade, S., & Pandit, S. (2025). An approach for crop recommendation with uncertainty estimation using machine learning. *Journal of Agricultural Informatics*, 16(1), 1–12. <https://doi.org/10.1016/j.jagif.2025.01.001>
- Wetzel, W., & Workman, J. (2025). Revolutionizing fertilizer analysis: Raman spectroscopy and machine learning deliver precision and speed. *Spectroscopy Online*. Retrieved from <https://www.spectroscopyonline.com/view/revolutionizing-fertilizer-analysis-raman-spectroscopy-and-machine-learning-deliver-precision-and-speed>
- Yang, X., & Zhang, Y. (2025). Improving soil pH prediction and mapping using anthropogenic data. *Journal of Environmental Management*, 248, 1–10. <https://www.tandfonline.com/doi/full/10.1080/10106049.2025.2482699>