

KLASIFIKASI JENIS PUPUK MENGGUNAKAN METODE BI-LSTM

Khairun Nisa¹, Mifthul Walid², Fathorrozi Ariyanto³

^{1,2,3}Teknik Informatika, Teknik, Universitas Islam Madura

¹ichazaen173@gmail.com, ²miftahul.walid@uim.ac.id, ³fathorroziariyanto7@gmail.com

ABSTRAK

Pertanian berkelanjutan membutuhkan pemilihan jenis pupuk yang tepat untuk mendukung efisiensi penggunaan sumber daya dan menjaga keberlanjutan lingkungan. Namun, keterbatasan informasi berbasis data sering kali menyebabkan ketidaktepatan dalam pemilihan pupuk. Riset ini menyoroti pengembangan sistem klasifikasi jenis pupuk dengan memanfaatkan algoritma deep learning Bidirectional Long Short-Term Memory (Bi-LSTM) berbasis dataset publikasi IEEE Access yang memuat parameter lingkungan meliputi Nitrogen, Fosfor, Kalium, jenis tanah, dan jenis tanaman, dengan nama pupuk sebagai variabel target; proses penelitian dilakukan melalui normalisasi data, pemisahan dataset menjadi data latih serta uji, pelatihan model Bi-LSTM, hingga evaluasi kinerja menggunakan Accuracy, Precision, Recall, dan F1-score, di mana hasil pengujian menunjukkan capaian akurasi 96,25% dengan nilai Precision, Recall, dan F1-score sebesar 0,962, serta dukungan visualisasi confusion matrix yang membuktikan tingkat kesalahan rendah sehingga menegaskan bahwa Bi-LSTM efektif untuk klasifikasi pupuk dan berpotensi menjadi solusi cerdas dalam membantu petani mengambil keputusan pemupukan yang lebih efisien, tepat sasaran, dan ramah lingkungan.

Kata kunci: Bi-LSTM, deep learning, klasifikasi pupuk, pertanian presisi, sistem pertanian cerdas

ABSTRACT

Sustainable agriculture requires accurate fertilizer selection to support resource efficiency and environmental sustainability. However, limited data-driven information often leads to inaccurate fertilizer decisions. This research highlights the creation of a fertilizer categorization framework by employing the Bidirectional Long Short-Term Memory (Bi-LSTM) deep neural network. The dataset, curated from IEEE Access repositories, incorporates agro-environmental variables including Nitrogen, Phosphorus, Potassium, soil characteristics, and crop varieties, with the fertilizer label serving as the prediction target. The workflow encompassed data standardization, partitioning the dataset into training and testing subsets, training the Bi-LSTM model, and assessing its effectiveness through indicators such as Accuracy, Precision, Recall, and F1-score. Outcomes from the assessment revealed that the Bi-LSTM approach attained a classification accuracy of 96.25%, while Precision, Recall, and F1-score each recorded a value of 0.962. The confusion matrix visualization further confirmed that the model could identify patterns with a low error rate. These findings highlight the effectiveness of Bi-LSTM in fertilizer classification and its potential as a smart solution to assist farmers in making more accurate, efficient, and environmentally friendly fertilization decisions.

Keywords: Bi-LSTM, deep learning, fertilizer type classification, precision agriculture, intelligent farming systems.

1. PENDAHULUAN

Dalam dunia pertanian modern, pengelolaan pupuk menjadi salah satu komponen penting dalam keberhasilan budidaya tanaman [1]. Penggunaan pupuk yang tidak tepat dapat menyebabkan kelebihan atau kekurangan nutrisi yang berdampak negatif pada pertumbuhan tanaman, hasil panen dan juga kondisi lingkungan. Masih banyak petani di tanah air yang kesulitan memilih pupuk yang pas untuk menunjang kebutuhan tumbuh kembang tanamannya, terutama karena keterbatasan informasi yang akurat dan berbasis data [2]. Jenis pupuk yang dibutuhkan oleh tanaman dipengaruhi oleh berbagai faktor seperti *Nitrogen*, *Potassium*, *Phosphorous*, *Soil Type*, dan *Crop Type*. Data terkait faktor-faktor ini bersifat kompleks dan dinamis, sehingga sulit di analisis secara manual. Akibatnya banyak petani masih menggunakan metode konvensional atau perkiraan, yang berisiko dapat menghasilkan keputusan pemupukan yang tidak efisien dan bahkan dapat berdampak buruk pada lingkungan [3]. Oleh karena itu, diperlukan pendekatan berbasis teknologi untuk membantu mengklasifikasikan jenis pupuk yang sesuai [4]. Metode yang dianggap menjanjikan untuk mengelola data kompleks dengan hubungan waktu yang erat adalah pendekatan *deep learning*, khususnya Bi-Directional Long Short-Term Memory (Bi-LSTM).

Penelitian ini diarahkan untuk merancang suatu kerangka klasifikasi jenis pupuk dengan pendekatan *deep learning* Bi-Directional Long Short-Term Memory (Bi-LSTM). Sistem yang dibangun difungsikan sebagai mesin rekomendasi pupuk yang selaras dengan riwayat data serta faktor lingkungan, sehingga mampu mengoptimalkan pemakaian pupuk sekaligus mendorong terciptanya pertanian berkelanjutan.

Beberapa penelitian terdahulu tentang prediksi kebutuhan pupuk telah dikembangkan, antara lain ; Penelitian oleh K & K.G, [5] berhasil mengembangkan sistem prediksi hasil panen dan rekomendasi pupuk menggunakan *Voting Based Ensemble Classifier* dengan akurasi 92%. Penelitian oleh *Theses & Bommireddy*, [6] berhasil mengembangkan sistem rekomendasi *machine*

learning untuk prediksi pemupukan, meningkatkan akurasi pemilihan pupuk dalam pertanian. Slaton et al. [7] menegaskan bahwa pemanfaatan model CSTV secara tepat mampu memperbaiki strategi pemupukan dan mendorong praktik agrikultur yang ramah lingkungan. Penelitian oleh *Musanase et al.*, [8] berhasil mengembangkan sistem rekomendasi tanaman dan pupuk berbasis data dan pembelajaran mesin, yang memanfaatkan sensor IoT untuk meningkatkan praktik pertanian. Penelitian oleh *Xing & Wang*, [9] Menegaskan bahwa penerapan teknologi berbasis presisi dalam pengairan dan pemupukan dapat memperbesar efisiensi sumber daya sekaligus menjaga keberlangsungan produksi pertanian. Penelitian oleh *Archana & Saranya*, [10] berhasil mengembangkan sistem rekomendasi tanaman berbasis algoritma *K Nearest Neighbor (KNN)* yang menunjukkan akurasi 80% dalam memprediksi hasil panen dan rekomendasi pupuk. Penelitian oleh *Bhola & Kumar*, [11] mengembangkan sistem prediksi tanaman berbasis *MLP* dengan akurasi 98,22% untuk rekomendasi hasil panen dan pupuk. Penelitian oleh *Khan et al.*, [12] mengembangkan sistem rekomendasi pupuk berbasis IoT dengan akurasi tinggi, yang meningkatkan efisiensi penggunaan pupuk dan produktivitas pertanian.


Hingga kini, kajian terdahulu belum memanfaatkan metode *deep learning* tipe Bi-LSTM dalam mengklasifikasikan ragam pupuk. Oleh sebab itu, riset ini ditujukan untuk merancang model klasifikasi pupuk berbasis Bi-LSTM. Bi-LSTM adalah metode yang unggul dalam menangkap pola data deret waktu dengan memproses informasi dari arah maju dan mundur [13]. Bi-LSTM juga memungkinkan analisis yang lebih komprehensif daripada metode lain. Kemampuan Bi-LSTM untuk memanfaatkan hubungan temporal dalam data menjadikannya pilihan yang bagus untuk memodelkan pola kompleks yang muncul sebagai akibat dari perubahan faktor lingkungan dalam hal klasifikasi jenis pupuk. mengingat pentingnya efisiensi penggunaan pupuk dalam mendukung keberlanjutan pertanian dan ketahanan pangan nasional [14]. Dengan populasi yang terus bertambah, kebutuhan akan hasil pertanian yang optimal menjadi semakin mendesak.

Kajian ini tidak sekedar memberi sumbangsih pada kemajuan teknologi pertanian presisi, namun juga turut menekan dampak merugikan terhadap ekosistem yang timbul akibat penggunaan pupuk berlebihan [15].

Riset ini difokuskan pada perancangan model klasifikasi pupuk berbasis Bi-LSTM untuk memberi rekomendasi sesuai kondisi lingkungan dan kebutuhan tanaman. Model ini diharapkan menjadi sarana bantu petani guna meningkatkan efektivitas dan hasil pengelolaan pupuk [16].

2. METODOLOGI PENELITIAN

Riset ini dilaksanakan melalui rangkaian prosedur sistematis guna menjamin ketepatan pengelompokan tipe pupuk. Diagram berikut menggambarkan alur metodologi penelitian yang dimulai dari pengumpulan dataset hingga evaluasi hasil klasifikasi menggunakan metode *Bi-LSTM* (Gambar 1).



Gambar 1. Alur Metodologi Penelitian

2.1 Dataset

Koleksi data yang dipakai dalam riset ini bersumber dari penelitian terdahulu berjudul "Internet of Things (IoT) Assisted Context Aware Fertilizer Recommendation" yang diterbitkan pada jurnal IEEE Access tahun 2022, *Potassium*, *Phosphorous*, *Soil Type*, dan *Crop Type*. Target dari dataset ini adalah jenis pupuk yang direkomendasikan (*Fertilizer Name*). Data diperoleh melalui ekstraksi grafik

menggunakan *WebPlotDigitizer* dan dilakukan validasi untuk memastikan kualitas data.

2.2 Normalization

Dalam tahap pra-pemrosesan data, diterapkan langkah penyeragaman skala memakai teknik *StandardScaler* agar setiap variabel berada pada rentang yang konsisten. Proses penskalaan ini mengonversi nilai fitur sehingga berdistribusi dengan rerata nol serta simpangan baku satu, yang pada gilirannya meningkatkan kestabilan perhitungan dan efektivitas performa model. Rumus *StandardScaler* yang digunakan dapat dilihat berikut:

$$X^1 = \frac{X - \mu}{\sigma} \quad (1)$$

Dataset dipisahkan menjadi dua kelompok, yakni training set (80%) untuk melatih algoritme dan testing set (20%) untuk mengevaluasi akurasi model.

2.3 Data Separation

Pada tahap pemisahan data, dataset dibagi menjadi data pelatihan (80%) dan data uji (20%). Data pelatihan digunakan untuk melatih Bi-LSTM mengenali pola, sedangkan data uji dipakai untuk mengukur kinerja klasifikasi kebutuhan pupuk.

2.4 Training Data

Jaringan Bi-LSTM dibangun dengan memanfaatkan data pelatihan, memakai konfigurasi parameter yang sudah dirancang sebelumnya, seperti jumlah *epoch*, *batch size*, dan menggunakan model *Adam optimizer* dengan *learning rate default*. Proses pelatihan dilakukan dengan mengoptimalkan bobot model menggunakan *Adam Optimizer*, serta menggunakan *Categorical Crossentropy* Berperan sebagai fungsi kerugian untuk menekan kesalahan klasifikasi multi-kategori. Selama pelatihan, model dipantau dengan data validasi guna mengevaluasi kinerja secara langsung sekaligus mencegah overfitting. Berikut rumus *Categorical Crossentropy*.

$$L = - \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (1)$$

2.5 Bi-LSTM Model

Pendekatan Bidirectional Long Short-Term Memory (Bi-LSTM) dalam penelitian ini dimanfaatkan untuk mengenali pola data dari dua jalur, yakni arah maju (forward) serta arah mundur (backward).

2.5.1 Forget Gate

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Gate forgetting Memiliki peran dalam menyaring data yang layak disimpan maupun diabaikan dari jejak memori terdahulu. Aktivasi sigmoid (σ) menghasilkan nilai 0 dan 1 yang menunjukkan bahwa 0 informasi diabaikan dan 1 dipertahankan.

2.5.2 Input Gate

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Input Gate ini mengatur pembaruan *cell state*, yaitu memori utama dalam unit LSTM.

2.5.3 Cell State Update

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$

Keadaan sel diperbarui dengan mengombinasikan informasi lama dari *Forget Gate* dan informasi baru dari *Input Gate*.

2.5.4 Output Gate

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Output Gate menentukan *hidden state* h_t , yang digunakan untuk memprediksi output pada langkah waktu saat ini.

2.6 Testing Data

Sesudah arsitektur Bi-LSTM rampung melalui tahap pelatihan, langkah selanjutnya ialah menguji performa dengan memanfaatkan himpunan data validasi. Data uji ini dipisahkan dari proses training, berjumlah sekitar 20% dari keseluruhan dataset. Model kemudian menghasilkan prediksi terhadap data tersebut, lalu prediksi tersebut dicocokkan dengan label aktual. Penilaian performa dilakukan menggunakan berbagai ukuran seperti akurasi, presisi, sensitivitas (recall), f1-score, serta confusion matrix guna menakar sejauh mana sistem mampu mengelompokkan kebutuhan pupuk secara tepat.

2.7 Accuracy

Proses pengujian model dilakukan untuk menilai akurasi performa dalam mengklasifikasikan kebutuhan pupuk, dengan menggunakan metrik Accuracy, Precision, Recall, dan F1-Score yang masing-masing memberikan gambaran berbeda: Accuracy menilai perbandingan prediksi benar terhadap total data uji, Precision menunjukkan tingkat ketelitian klasifikasi tiap kelas, Recall menggambarkan kemampuan mendeteksi seluruh data sesuai kelasnya, sementara F1-Score merepresentasikan rata-rata harmonis antara Precision dan Recall sebagai bentuk keseimbangan; hasil evaluasi tersebut kemudian divisualisasikan dalam Confusion Matrix guna memperlihatkan distribusi prediksi dibandingkan label aktual.

Accuracy (Akurasi Multi-Kelas)

$$Accuracy = \frac{\sum TP}{\sum TP + \sum FP + \sum FN} \quad (1)$$

Precision

$$Precision_{macro} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i} \quad (2)$$

Recall

$$Recall_{macro} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \quad (3)$$

F1-Score

$$F1_{macro} = \frac{1}{N} \sum_{i=1}^N 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (4)$$

2.8 Comparison

Dalam studi ini, sejumlah ukuran penilaian seperti Accuracy, Precision, Recall, dan F1-Score dimanfaatkan untuk menilai perbedaan performa model. Tujuan utama dari proses perbandingan tersebut ialah menakar sejauh mana model Bi-LSTM mampu melakukan klasifikasi kebutuhan pupuk dengan ketepatan yang lebih baik dibanding pendekatan lain atau model dasar. Hasil penilaian ini diarahkan untuk mengetahui efektivitas model dalam mengenali pola pada data sekaligus meningkatkan mutu prediksi yang dihasilkan. Selain itu, perbandingan juga dilakukan dengan melihat hasil Matriks Konflik, yang menunjukkan bagaimana keberhasilan prediksi dan kesalahan tersebar di setiap kelas.

2.9 Result

Kinerja model Bi-LSTM ditampilkan dalam representasi tabel serta diagram sehingga memudahkan proses telaah. Proses penilaian dilakukan memakai Confusion Matrix, Precision, Recall, F1-Score, dan Accuracy sebagai tolok ukur efektivitas klasifikasi. Untuk memperjelas pola distribusi prediksi, digunakan visualisasi heatmap dari Confusion Matrix. Temuan ini memberikan gambaran seberapa baik model dapat mengenali pola serta menghasilkan klasifikasi yang tepat.

3. HASIL DAN PEMBAHASAN

Kajian ini berorientasi pada pemetaan klasifikasi pupuk dalam sistem hidroponik cerdas dengan memanfaatkan metode Bi-LSTM. Performa model ditaksir melalui Confusion Matrix, Precision, Recall, F1-Score, dan Accuracy sebagai parameter utama.

3.1 Identifikasi Data

Dalam uraian sebelumnya dijelaskan bahwa kumpulan data yang dipakai bersumber dari data sekunder yang dihimpun oleh Khan dkk. [12] melalui publikasi berjudul “Internet of Things (IoT) Assisted Context Aware Fertilizer Recommendation” pada tahun 2022.

Dataset ini mencakup 1.200 observasi dengan enam atribut, meliputi unsur Nitrogen, Kalium, Fosfor, tipe tanah, jenis tanaman, serta nama pupuk yang berfungsi sebagai variabel target. Berikut ditampilkan lima baris pertama dari data yang menjadi acuan penelitian dan diperlihatkan pada bagian berikut (Gambar 2).

	Soil Type	Crop Type	Nitrogen	Potassium	Phosphorous	Fertilizer Name
0	6	6	29	14	7	5
1	4	5	32	14	7	5
2	4	4	30	12	8	5
3	5	6	30	6	8	5
4	5	4	27	14	7	5

Gambar 2. Tampilan dataset

3.2 Pelatihan Model

3.2.1 Normalisasi Data


Proses penyamaan skala data dilakukan menggunakan fungsi StandardScaler() agar setiap variabel berada pada ukuran yang konsisten, sehingga mempercepat laju konvergensi model ketika tahap pelatihan berlangsung (Gambar 3).

```
# Normalisasi Data
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)
```

Gambar 3. Potongan Kode Proses Normalisasi Data

3.2.2 Training Model


Konfigurasi pembelajaran yang dipakai meliputi jumlah iterasi sebanyak 50, ukuran batch 32, serta pemakaian algoritma Adam sebagai pengoptimal dengan fungsi kerugian categorical crossentropy (Gambar 4).



Gambar 4. Grafik Akurasi Model per Epoch

Akurasi model terhadap jumlah epoch selama pelatihan dan validasi ditunjukkan pada (Gambar 3) di atas. Terdapat dua garis yang

menggambarkan performa model, yaitu akurasi pada data pelatihan (*train accuracy*) ditunjukkan dengan garis biru dan akurasi pada data validasi (*validation accuracy*) ditunjukkan dengan garis *oranye*. Dari grafik tersebut terlihat bahwa akurasi meningkat secara signifikan pada awal pelatihan, terutama dalam 10 epoch pertama. Setelah itu, akurasi cenderung stabil dan mendekati nilai maksimal, yaitu diatas 95%. Keterkaitan erat antara kurva akurasi pelatihan dan validasi menegaskan bahwa model tidak mengalami overfitting berarti. Ini menunjukkan model mampu bekerja baik pada data latih sekaligus menjaga generalisasi terhadap data validasi. Secara umum, hasilnya membuktikan bahwa model stabil dan andal dalam melakukan prediksi atau klasifikasi. Sementara itu, (Gambar 5) juga menampilkan grafik nilai loss selama proses pelatihan dan validasi.



Gambar 5. Grafik Loss per Epoch

Gambar 5 menampilkan grafik loss pada pelatihan Bi-LSTM. Di awal proses, nilai loss pada data latih dan validasi turun tajam, lalu berangsur stabil mendekati nol seiring bertambahnya epoch. Pola penurunan yang sejalan pada kedua data menandakan model belajar efektif tanpa gejala overfitting, sehingga kinerjanya optimal dan mampu melakukan generalisasi dengan baik.

3.3 Evaluasi Model


Model divalidasi menggunakan data uji terpisah, di mana hasil prediksi kemudian dikorelasikan dengan nilai aktual untuk menilai kinerja Bi-LSTM dalam mengelompokkan jenis pupuk; performa sistem ini diukur melalui metrik evaluasi meliputi Accuracy, Precision,

Recall, dan F1-Score, dengan rincian capaian ditampilkan pada tabel hasil pengujian.

Tabel 1. Hasil Evaluasi Model Bi-LSTM

Metrik	Nilai
Accuracy	96.25%
Precision	0.962
Recall	0.962
F1-Score	0.962

Model yang dikembangkan terbukti memiliki performa optimal dengan tingkat akurasi mencapai 96,25%, disertai nilai Precision, Recall, dan F1-Score yang sama tinggi (0,962) sehingga menunjukkan kestabilan kinerja. Hasil ini menandakan bahwa, dengan kesalahan yang relatif rendah, model mampu melakukan klasifikasi kebutuhan pupuk secara tepat sekaligus konsisten dalam mengenali tiap kategori. Kombinasi akurasi tinggi serta keseimbangan antar-metrik membuktikan keandalan model, yang semakin dipertegas melalui visualisasi Confusion Matrix dalam bentuk heatmap (Gambar 6).



Gambar 6. Visualisasi Confusion Matrix dalam bentuk Heatmap

Gambar 6 memperlihatkan representasi heatmap confusion matrix yang menggambarkan enam kategori kebutuhan pupuk. Angka pada diagonal utama menandakan prediksi yang sesuai dengan label

aslanya, sedangkan angka di luar diagonal menunjukkan adanya salah klasifikasi. Contohnya, terdapat 48 prediksi tepat pada kelas 4 dan 43 pada kelas 1, yang mengindikasikan bahwa model Bi-LSTM mampu melakukan pengelompokan data dengan ketepatan yang cukup tinggi. Walaupun masih terdapat sejumlah kecil kesalahan klasifikasi, proporsinya relatif rendah sehingga tidak memberikan pengaruh besar pada performa keseluruhan. Hal ini menandakan bahwa model tersebut memiliki kemampuan generalisasi yang mumpuni dalam mengenali pola dari data dan memetakan ke kategori pupuk yang relevan.

4. KESIMPULAN

Riset ini sukses membangun rancangan klasifikasi kategori pupuk dengan memanfaatkan algoritma Bi-LSTM yang menghasilkan tingkat ketepatan mencapai 96,25%. Pengujian performa memperlihatkan bahwa precision, recall, dan F1-score sama-sama berada di angka 0,962, yang mengindikasikan model dapat mengenali jenis pupuk secara akurat dan konsisten. Temuan dari confusion matrix juga menegaskan kemampuan sistem dalam menangkap pola data sekaligus menekan kesalahan prediksi. Oleh karena itu, pendekatan Bi-LSTM terbukti handal dalam mendukung proses penentuan keputusan di bidang pertanian berbasis data, terutama untuk mengelompokkan jenis pupuk yang paling sesuai. Kajian ini berkontribusi pada penguatan teknologi pertanian presisi yang tidak hanya meningkatkan efektivitas pemakaian pupuk, tetapi juga berpotensi mengurangi risiko kerusakan lingkungan.

DAFTAR PUSTAKA

- [1] S. Ch and C. Srinivasarao, "Programmes and Policies for Improving Fertilizer Use Efficiency in Agriculture," *Indian J. Fertil.*, vol. 17, no. 3, pp. 226–254, 2021, [Online]. Available: <https://www.researchgate.net/publication/350687644>
- [2] Kementrian Lingkungan Hidup dan Kehutanan, *SLHI_2022_upload_final_77f9948571*. 2022.
- [3] I. Pergner and C. Lippert, "On the effects that motivate pesticide use in perspective of designing a cropping system without pesticides but with mineral fertilizer—a review," *Agron. Sustain. Dev.*, vol. 43, no. 2, 2023, doi: 10.1007/s13593-023-00877-w.
- [4] F. R. Tulungen, "Teknologi Pertanian Presisi untuk Meningkatkan Efisiensi Produksi Padi di Indonesia," *J. Cahaya Mandalika*, vol. 5, no. 2, pp. 720–727, 2024, [Online]. Available: <http://ojs.cahayamandalika.com/index.php/JCM>
- [5] A. K and D. S. K.G, "Crop Yield Prediction, Forecasting and Fertilizer Recommendation using Voting Based Ensemble Classifier," *Int. J. Comput. Sci. Eng.*, vol. 7, no. 5, pp. 1–4, 2020, doi: 10.14445/23488387/ijcse-v7i5p101.
- [6] E. Theses and D. R. Bommireddy, "Recommendation System using machine learning for fertilizer prediction," 2024.
- [7] N. A. Slaton *et al.*, "Models and sufficiency interpretation for estimating critical soil test values for the Fertilizer Recommendation Support Tool," *Soil Sci. Soc. Am. J.*, vol. 88, no. 4, pp. 1419–1437, 2024, doi: 10.1002/saj2.20704.
- [8] C. Musanase, A. Vodacek, D. Hanyurwimfura, A. Uwitonze, and I. Kabandana, "Data-Driven Analysis and Machine Learning-Based Crop and Fertilizer Recommendation System for Revolutionizing Farming Practices," *Agric.*, vol. 13, no. 11, 2023, doi: 10.3390/agriculture13112141.
- [9] Y. Xing and X. Wang, "Precise application of water and fertilizer to crops: challenges and opportunities," *Front. Plant Sci.*, vol. 15, no. December, pp. 1–17, 2024, doi: 10.3389/fpls.2024.1444560.
- [10] K. Archana and D. K. G. Saranya, "Crop yield prediction, forecasting and fertilizer recommendation using Data mining algorithm," *Int. J. Comput. Sci. Eng.*, vol. 9, no. 1, pp. 76–79, 2020.
- [11] A. Bhola and P. Kumar, "MI-Csfr: a

-
- Unified Crop Selection and Fertilizer Recommendation Framework Based on Machine Learning,” *Scalable Comput.*, vol. 25, no. 5, pp. 4411–4427, 2024, doi: 10.12694/scpe.v25i5.2599.
- [12] A. A. Khan, M. Faheem, R. N. Bashir, C. Wechtaisong, and M. Z. Abbas, “Internet of Things (IoT) Assisted Context Aware Fertilizer Recommendation,” *IEEE Access*, vol. 10, no. December, pp. 129505–129519, 2022, doi: 10.1109/ACCESS.2022.3228160.
- [13] H. Alizadegan, B. Rashidi Malki, A. Radmehr, H. Karimi, and M. A. Ilani, “Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction,” *Energy Explor. Exploit.*, 2024, doi: 10.1177/01445987241269496.
- [14] J. Penuelas, F. Coello, and J. Sardans, “A better use of fertilizers is needed for global food security and environmental sustainability,” *Agric. Food Secur.*, vol. 12, no. 1, pp. 1–9, 2023, doi: 10.1186/s40066-023-00409-5.
- [15] S. Sharma and A. Srushtideep, “Precision Agriculture and Its Future,” *Int. J. Plant Soil Sci.*, vol. 34, no. 24, pp. 200–204, 2022, doi: 10.9734/ijpss/2022/v34i242630.
- [16] A. Ali, T. Hussain, N. Tantashutikun, N. Hussain, and G. Cocetta, “Application of Smart Techniques, Internet of Things and Data Mining for Resource Use Efficient and Sustainable Crop Production,” *Agric.*, vol. 13, no. 2, 2023, doi: 10.3390/agriculture13020397.