

Full Paper

Detection of Nutrition Deficiency in Iceberg Lettuce Plants Using Autoencoder and Multilayer Perceptron Methods

Sadra Din Azizi Muhammad^{1*}Universitas Islam Sultan Agung, Semarang,
Indonesia,sadradin1305@std.unissula.ac.id**Sam Farisa Chaerul Haviana²,**Universitas Islam Sultan Agung, Semarang,
Indonesia,sam@unissula.ac.id

*Corresponding Author

ABSTRACT


Iceberg lettuce was selected as the research object because its leaves show clear visual responses to nutrient deficiencies, while visual inspection methods commonly used by small- and medium-scale growers remain subjective. This study aims to develop an automated detection system for nutrient deficiency using an autoencoder combined with a Multilayer Perceptron (MLP). The dataset was sourced from Kaggle and categorized into four classes: Nitrogen, Phosphorus, Potassium, and Healthy. The preprocessing stage included converting images from BGR to HSV, resizing to 128×128 pixels, normalizing to 0–1, and applying an 80:20 train–test split. Feature extraction was performed using the autoencoder (encoder, bottleneck, decoder), while classification was carried out using the MLP (input, hidden, and output layers). Evaluation using a confusion matrix showed an accuracy of 86%, precision of 89%, recall of 87%, and an F1-score of 88%. The system has been implemented in a user-friendly web application that allows users to upload images and obtain detection results instantly. In conclusion, integrating autoencoder and MLP proved effective for automated nutrient deficiency detection in iceberg lettuce, providing a more objective alternative to conventional visual diagnosis.

KEYWORDS

Lettuce Iceberg; Image Processing; Autoencoder; Multilayer Perceptron

Muhammad. S. D. A. Haviana. S. F.C. (2025). Detection of Nutrition Deficiency in Iceberg Lettuce Plants Using Autoencoder and Multilayer Perceptron Methods. *jasmed*, 3(2), pp. 86-100. <https://doi.org/10.20895/jasmed.v3i2.10130>

Article Submitted 14/11/2025. Revision uploaded 26/11/2025ss. Accepted 06/12/2025.

© 2025 by the authors of this article. Published under CC-BY 

1. INTRODUCTION

Pertumbuhan dan produktivitas tanaman sangat dipengaruhi oleh ketersediaan unsur hara yang cukup seimbang. Kekurangan unsur hara atau defisiensi nutrisi menyebabkan perubahan fisiologis dan morfologis pada tanaman, terutama pada bagian daun, seperti klorosis, nekrosis, hingga perubahan bentuk. Kondisi tersebut dapat menurunkan hasil panen dan menimbulkan kerugian ekonomi yang signifikan bagi petani. Oleh karena itu, deteksi dini terhadap gejala kekurangan nutrisi sangat penting agar tindakan korektif dapat segera dilakukan sebelum kondisi tanaman memburuk.

Tanaman *lettuce iceberg* (*Lactuca sativa* var. *Capitata*) merupakan salah satu komoditas hortikultura yang banyak dibudidayakan secara hidroponik karena memiliki nilai ekonomi tinggi, waktu panen relatif singkat (70-100 hari), serta permintaan pasar yang meningkat terutama pada sektor kuliner dan gaya hidup sehat. Namun, seperti tanaman lainnya, *lettuce iceberg* rentan terhadap kekurangan unsur hara makro seperti nitrogen (N), fosfor (P), dan kalium (K), yang berdampak langsung pada penurunan kualitas daun serta hasil panen [1]. Dalam sistem hidroponik keseimbangan nutrisi menjadi aspek yang sangat krusial karena larutan nutrisi merupakan satu-satunya sumber berharga bagi tanaman [2]. Ketidakseimbangan sedikit saja dapat menimbulkan perubahan signifikan pada pertumbuhan dan warna daun.

Selama ini, metode deteksi defisiensi nutrisi umumnya dilakukan secara visual berdasarkan pengalaman petani atau pengelola kebun. Meskipun sederhana dan tidak memerlukan alat khusus, metode ini bersifat subjektif, tergantung pada keahlian individu, dan rawan kesalahan diagnosis. Faktor pencahayaan, warna daun alami, serta kondisi lingkungan seperti suhu dan kelembapan juga dapat memengaruhi persepsi warna daun, sehingga hasil pengamatan sering kali tidak konsisten. Kondisi ini mendorong perlunya pendekatan yang lebih objektif dan otomatis untuk mendeteksi kekurangan nutrisi, terutama pada sistem pertanian presisi (*precision agriculture*). Selain itu, penelitian menunjukkan bahwa diagnosis visual sering kali gagal membedakan gejala defisiensi antar unsur hara yang memiliki pola perubahan warna serupa [3].

Teknik *image processing* memiliki peranan penting dalam mendeteksi perubahan visual pada daun yang menjadi indikator awal defisiensi nutrisi. Proses pengolahan citra seperti segmentasi warna, deteksi tepi, dan analisis tekstur membantu memisahkan area daun sehat dan bermasalah secara lebih objektif dibanding pengamatan manual. Penelitian lain menunjukkan bahwa kombinasi metode *HSV color conversion*, *adaptive threshold segmentation*, *canny edge detection*, dan *gradient-based refinement* mampu meningkatkan ketelitian dalam identifikasi area daun yang mengalami kekurangan unsur hara, sehingga memperkuat peran *image processing* sebagai tahap fundamental dalam sistem deteksi berbasis AI (*Artificial Intelligence*) [4].

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan pembelajaran mendalam (*Deep Learning*) telah membuka peluang besar dalam bidang pertanian digital. Model seperti *Convolutional Neural Network* (CNN) terbukti mampu mengklasifikasikan kondisi daun dengan tingkat akurasi tinggi, seperti penelitian yang berhasil mendeteksi defisiensi nutrisi pada tanaman padi dengan akurasi mencapai 97,73%. Namun, arsitektur CNN memiliki kompleksitas tinggi dan membutuhkan sumber daya komputasi besar, sehingga kurang efisien untuk implementasi di lapangan atau perangkat dengan kapasitas terbatas [5]. Selain itu, model CNN yang dalam sering kali sulit dijelaskan (*black box*), membuat interpretasi hasilnya menjadi tantangan tersendiri bagi pengguna non-teknis seperti petani atau praktisi lapangan.

Sebagai alternatif, pendekatan berbasis *autoencoder* dan *Multilayer Perceptron* (MLP) mulai banyak dikembangkan karena menawarkan efisiensi dan kinerja yang kompetitif. *Autoencoder* merupakan jaringan saraf tiruan yang digunakan untuk reduksi dimensi dan ekstraksi fitur, sementara MLP berfungsi sebagai pengklasifikasi. Kombinasi *Convolutional Autoencoder* (CAE) dengan MLP mampu menghasilkan representasi fitur citra yang kompak tanpa kehilangan informasi penting, sehingga cocok untuk sistem klasifikasi citra daun tanaman [6]. Di sisi lain, penelitian lain membuktikan bahwa model berbasis *autoencoder* dapat efektif dalam mendeteksi pola anomali nutrisi pada daun melalui rekonstruksi citra [7].

Pada penelitian yang membuktikan bahwa arsitektur MLP-Mixer berbasis MLP dapat mencapai akurasi lebih dari 92% pada klasifikasi defisiensi nutrisi tanaman padi menggunakan citra RGB (Red, Green, Blue). Kombinasi kedua model ini terbukti ringan namun efektif dalam pengenalan pola visual non-linear yang kompleks [8]. Kombinasi kedua model ini terbukti ringan namun efektif dalam pengenalan pola visual non-linear yang kompleks. Di sisi lain, penelitian lain yang menekankan bahwa model berbasis *autoencoder* dapat digunakan tidak hanya untuk rekonstruksi citra, tetapi juga untuk mendeteksi pola anomali seperti kekurangan unsur hara dengan hasil yang efisien secara

komputasi [9]. Selain itu, penelitian lain menunjukkan bahwa deteksi kekurangan nutrisi pada tanaman selada hidroponik dapat dilakukan secara real-time menggunakan metode YOLO-NPK, menegaskan potensi besar teknologi *deep learning* dalam pemantauan kondisi tanaman modern [10].

Berdasarkan latar belakang tersebut, penelitian ini mengusulkan sistem deteksi kekurangan nutrisi pada tanaman *lettuce iceberg* menggunakan metode *autoencoder* dan *Multilayer Perceptron* (MLP). Sistem ini bertujuan mengekstraksi fitur penting dari citra daun secara otomatis dan mengklasifikasikannya ke dalam empat kategori: *nitrogen deficiency*, *phosphorus deficiency*, *potassium deficiency*, dan *healthy*. Dataset diperoleh dari platform publik Kaggle, dengan data diolah melalui proses *image processing* seperti konversi ruang warna BGR (Blue, Green, Red) ke HSV (Hue, Saturation, Value), resize gambar menjadi 128*128 piksel, dan normalisasi ke skala 0-1.

Selain berfokus pada keakuratan model, penelitian ini juga menekankan aspek efisiensi dan kemudahan penggunaan melalui implementasi antarmuka berbasis web menggunakan streamlit. Aplikasi ini memungkinkan pengguna, termasuk petani dan praktisi pertanian, untuk mengunggah citra daun dan memperoleh hasil klasifikasi secara langsung melalui browser tanpa perlu menginstal perangkat lunak tambahan. Pendekatan ini diharapkan dapat memperluas adopsi teknologi AI di sektor pertanian dengan mengurangi hambatan teknis dan biaya.

Meskipun kombinasi *autoencoder* dan MLP telah digunakan pada beberapa penelitian sebelumnya, studi ini memiliki perbedaan pada konteks penerapan dan kondisi datanya. Penelitian ini berfokus pada dataset *lettuce iceberg* dengan jumlah data terbatas, sehingga diperlukan pendekatan ekstraksi fitur yang lebih efisien agar model tetap bekerja optimal. Selain itu, penelitian ini juga memberikan kontribusi praktis melalui implementasi sistem berbasis web menggunakan streamlit, sehingga hasil klasifikasi dapat digunakan secara langsung oleh pengguna akhir seperti petani atau pengelola kebun.

Penelitian ini diharapkan dapat memberikan kontribusi nyata terhadap pengembangan pertanian cerdas (smart agriculture) dengan menyediakan sistem pendeteksi otomatis yang efisien dan akurat. Dengan tingkat akurasi tinggi dan implementasi berbasis aplikasi web, sistem ini dapat diakses oleh petani kecil hingga menengah tanpa memerlukan perangkat keras berbiaya tinggi. Selain itu, hasil penelitian ini dapat menjadi dasar bagi pengembangan sistem monitoring nutrisi tanaman berbasis visi komputer dan AI di masa mendatang, yang berperan penting dalam meningkatkan produktivitas, efisiensi sumber daya, serta ketahanan pangan di era digital.

2. METHODS

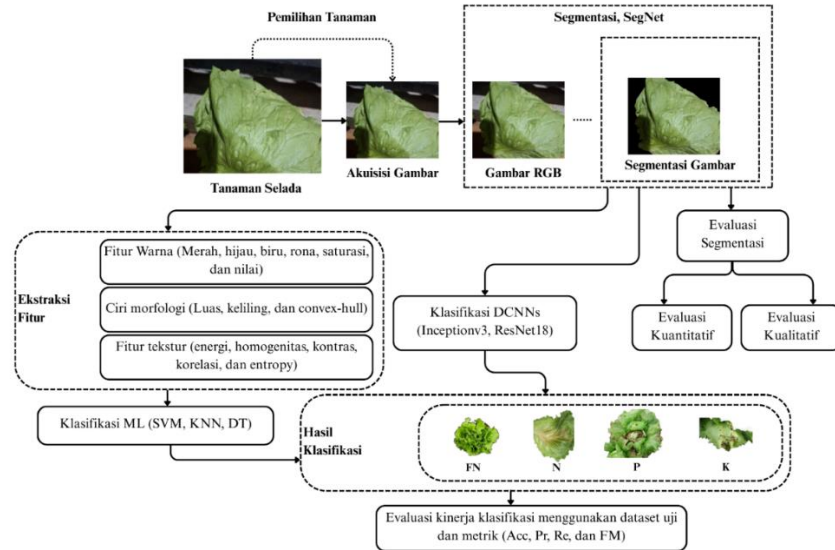
A. Dasar Teori

1) Defisiensi Nutrisi

Defisiensi nutrisi terjadi ketika tanaman tidak memperoleh unsur hara esensial dalam jumlah yang cukup untuk mendukung fungsi fisiologisnya. Pada sistem hidroponik, kondisi ini lebih mudah terjadi karena seluruh nutrisi disuplai melalui larutan, sehingga ketidakseimbangan sedikit saja dapat memicu gejala seperti klorosis, pigmentasi abnormal, hingga nekrosis pada daun. Penelitian lain mencatat bahwa kekurangan nitrogen, fosfor, dan kalium pada tanaman selada menghasilkan tanda visual yang berbeda, yang dapat digunakan sebagai indikator awal stres nutrisi [11].

Metode deteksi berbasis pengamatan visual memiliki keterbatasan karena bersifat subjektif dan dipengaruhi kondisi lingkungan. Oleh karena itu, teknologi citra digital dan kecerdasan buatan mulai diterapkan untuk meningkatkan akurasi identifikasi defisiensi nutrisi. Penelitian yang menunjukkan bahwa penggunaan hyperspectral imaging (HSI) yang dikombinasikan dengan *deep learning* mampu mengenali pola spektral khas dari setiap jenis defisiensi pada daun selada, bahkan di bawah variasi pencahayaan [12].


2) Pengolahan Citra



Gambar 1 Image Processing.

Pada Gambar 1 alur *image processing* untuk mendeteksi kekurangan nutrisi pada tanaman selada, dimulai dari pemilihan tanaman dan pengambilan gambar, kemudian dilanjutkan dengan segmentasi citra menggunakan model *Deep Learning* seperti SegNet untuk memisahkan daun dari latar belakang. Setelah segmentasi, dilakukan ekstraksi fitur yang mencakup fitur warna (RGB dan HSV), fitur morfologis (area, perimeter, convex hull), serta fitur tekstur (*energy*, *homogeneity*, *contrast*, *correlation*, dan *entropy*). Fitur-fitur tersebut selanjutnya digunakan sebagai input untuk model klasifikasi, baik model *Machine Learning* seperti SVM, KNN, dan *Decision Tree*, maupun model *Deep Learning* seperti InceptionV3 dan ResNet18. Hasil klasifikasi menentukan jenis defisiensi nutrisi FN (*Full Nutrient*), N (*Nitrogen*), P (*Phosphorus*), atau K (*Potassium*) dan kinerjanya dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* [13].

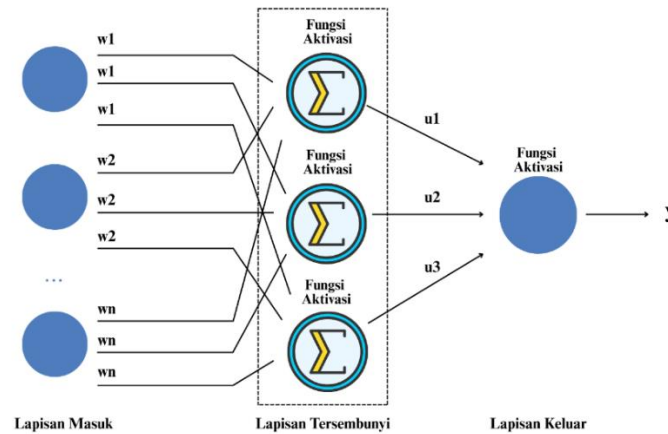
3) Autoencoder



Gambar 2 Autoencoder.

Gambar 2 menunjukkan struktur dasar *autoencoder* yang terdiri dari tiga komponen utama, yaitu *encoder*, *bottleneck*, dan *decoder*. *Encoder* berfungsi mengubah *input* menjadi representasi laten berdimensi rendah, *bottleneck* menjadi lapisan tersempit yang memaksa jaringan mempelajari fitur paling penting dari data, sedangkan *decoder* merekonstruksi kembali *input* dari representasi tersebut. Dalam deteksi penyakit tanaman, *autoencoder* digunakan untuk mengekstraksi fitur penting dari citra daun secara otomatis tanpa memerlukan label, yang selanjutnya menjadi masukan bagi model MLP pada tahap klasifikasi.

4) Multilayer Perceptron

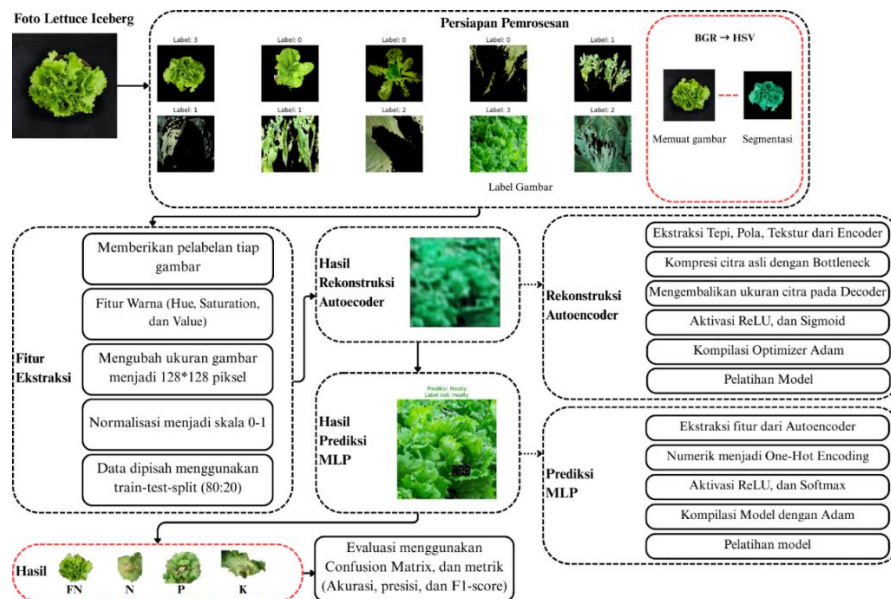


Gambar 3 Multilayer Perceptron (MLP).

Jaringan pada Gambar 3 terdiri dari tiga komponen utama, yaitu *input layer*, *hidden layer*, dan *output layer*. *Input layer* berfungsi sebagai titik masuk data, di mana setiap neuron menerima fitur dari citra seperti nilai piksel, warna, atau tekstur. *Hidden layer* memproses informasi tersebut melalui pembobotan dan fungsi aktivasi untuk menangkap pola *non-linear* yang kompleks. Sementara itu, *output layer* menghasilkan prediksi akhir dengan menerima *output* dari *hidden layer* dan mengolahnya melalui mekanisme pembobotan dan aktivasi, sehingga jaringan dapat menghasilkan nilai klasifikasi atau prediksi sesuai kebutuhan [14].

B. Metode Penelitian

Pada tahap ini dilakukan integrasi antara *autoencoder* dan *Multilayer Perceptron* (MLP) sebagai pendekatan untuk mendeteksi kekurangan nutrisi pada tanaman berdasarkan citra daun. Kombinasi ini memungkinkan sistem mengekstraksi fitur penting secara otomatis melalui *autoencoder* dan mengklasifikasikannya ke dalam kategori defisiensi nutrisi menggunakan MLP. Penelitian lain juga menegaskan kemampuan *autoencoder* konvolusional dalam mengekstraksi fitur citra daun tanpa memerlukan segmentasi atau pemrosesan manual yang kompleks, sehingga menghasilkan representasi fitur yang lebih padat dan mudah diolah oleh model klasifikasi seperti MLP [15]. Berikut ini merupakan sebuah gambar *workflow* dari penelitian ini yang melakukan beberapa tahapan, sebagai berikut:



Gambar 4 Workflow Penelitian.

Penelitian ini menggunakan tahapan meliputi pengumpulan data, *preprocessing*, pelatihan model *autoencoder* dan MLP, serta evaluasi performa sistem. Dataset yang digunakan bersumber dari *platform kaggle*, yang terdiri atas empat kelas citra daun *lettuce iceberg*, yaitu *nitrogen deficiency*, *phosphorus deficiency*, *potassium deficiency*, dan *healthy*.

1) Pengambilan Data

Proses dimulai dengan pengumpulan citra tanaman *lettuce iceberg* yang diambil dari dataset. Gambar-gambar ini menjadi *input* awal sistem.

2) Preprocessing Dataset

Tahapan awal dilakukan dengan konversi warna citra dari format BGR ke HSV untuk memisahkan informasi warna dari tingkat kecerahan. Selanjutnya, gambar diubah ukurannya menjadi 128*128 piksel agar seragam, kemudian dinormalisasi ke rentang 0-1 untuk mempercepat konvergensi pelatihan model. Dataset dibagi menggunakan skema *train-test split* dengan rasio 80:20, 80% untuk pelatihan 20% untuk pengujian.

3) Arsitektur Autoencoder

Autoencoder digunakan untuk melakukan ekstraksi fitur tanpa supervisi dengan tiga lapisan utama, yaitu *encoder*, *bottleneck*, dan *decoder*. *Encoder* berfungsi mereduksi dimensi *input* dan mempelajari representasi laten citra daun, *bottleneck* menjadi lapisan kompresi data, dan *decoder* merekonstruksi kembali citra untuk memastikan fitur penting tetap terjaga.

4) Arsitektur MLP

Setelah pelatihan *autoencoder* selesai, bagian *encoder* dipisahkan untuk menghasilkan *feature vector* yang digunakan sebagai *input* pada MLP. Arsitektur MLP terdiri dari tiga lapisan utama:

- Dense layer 1: 256 neuron dengan fungsi aktivasi ReLU, dropout 30%.
- Dense layer 2: 128 neuron dengan fungsi aktivasi ReLU, dropout 30%.
- Output layer: 4 neuron dengan fungsi aktivasi Softmax untuk klasifikasi multiclass.

Model dikompilasi menggunakan optimizer Adam, loss function categorical crossentropy, dan metrik akurasi. Pelatihan dilakukan selama 25 epoch, dengan batch size 32.

5) Evaluasi Model

Evaluasi performa model dilakukan menggunakan *Confusion Matrix*, akurasi, presisi, *recall*, dan *F1-Score*. Rumus yang digunakan mengacu pada pendekatan umum (scikit-learn):

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

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

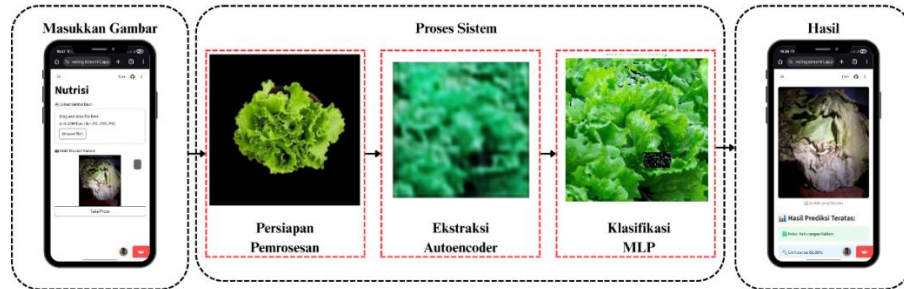
$$F1 - Score = \frac{2 * (Precision * Recall)}{Precision + Recall} \quad (4)$$

Dimana:

- TP adalah jumlah prediksi positif yang benar
- TN adalah jumlah prediksi negatif yang benar
- FP adalah jumlah prediksi positif yang salah
- FN adalah jumlah prediksi yang salah

6) Penggunaan Sistem

Berikut hasil analisa alur kerja penggunaan sistem yang dilakukan oleh user dalam bentuk *workflow*.



Gambar 5 Alur Kerja Sistem.

Pada gambar diatas memiliki beberapa tahapan sebagai berikut:

- User* membuka aplikasi kemudian akan muncul tampilan awal *website*.
- User* mengunggah gambar bisa dengan tiga cara, yaitu menggunakan *drag and drop file here*, *browser file* atau *take photo* untuk memasukkan citra yang ingin dideteksi.
- Selanjutnya sistem akan memproses citra daun tersebut dengan melihat ciri-ciri warna, bercak, dan sebagainya untuk menentukan daun memiliki kekurangan nutrisi atau tidak.
- Terakhir, user akan mendapatkan *input* dari sistem berupa citra daun yang sudah dideteksi dari citra daun yang user masukkan ke sistem.


3. RESULT

1) Pengumpulan Dataset

Proses pengumpulan data dilakukan dengan menghimpun citra daun *lettuce iceberg* yang diklasifikasikan ke dalam empat kategori, yaitu sehat (*healthy*), kekurangan nitrogen (*nitrogen deficiency*), kekurangan fosfor (*phosphorus deficiency*), dan kekurangan kalium (*potassium deficiency*). Dataset diperoleh dari sumber digital, kemudian disusun dalam direktori terpisah sesuai label kelas untuk memudahkan proses pelatihan model. Dalam penelitian ini digunakan total 183 citra daun, yang kemudian dibagi menggunakan teknik *train-test split* dengan 147 citra untuk pelatihan (*train*) dan 36 citra untuk pengujian (*test*) sehingga evaluasi kinerja model dapat dilakukan secara objektif pada data yang belum pernah dilihat sebelumnya.

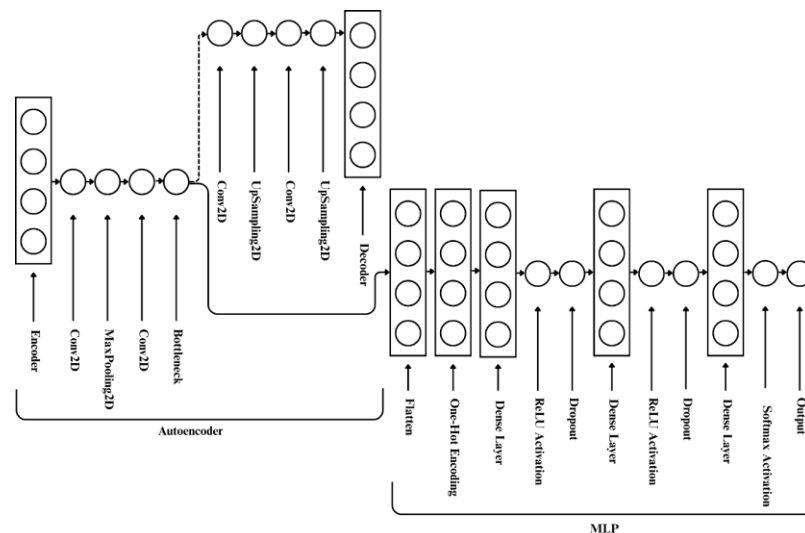
Tabel 1 Sampel Dataset

| Citra | Deskripsi |
|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|
|  | Tanaman yang memiliki nutrisi yang terpenuhi, terlihat dari warna daun yang hijau merata dan pertumbuhan yang baik. |
|  | Tanaman yang mengalami defisiensi nitrogen, ditandai dengan warna daun yang menguning secara menyeluruh, terutama pada tua. |
|  | Tanaman yang mengalami kekurangan fosfor, terlihat dari warna daun yang berubah menjadi ungu atau kemerahan pada bagian bawah. |

| Citra | Deskripsi |
|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
|  | Tanaman yang mengalami defisiensi kalium, ditunjukkan oleh tepi daun yang mengering atau berwarna coklat serta bentuk daun yang tidak normal. |

2) Arsitektur Model *Autoencoder* dan MLP

Arsitektur sistem yang dibuat dengan menggabungkan dua model, yaitu *autoencoder* dan *Multilayer Perceptron* (MLP) untuk mendeteksi kekurangan nutrisi pada daun *lettuce iceberg*. *Autoencoder* berfungsi sebagai ekstraktor fitur laten melalui proses encoding, sedangkan MLP digunakan sebagai klasifikator untuk memprediksi kondisi nutrisi berdasarkan fitur yang telah diekstraksi.



Gambar 6 Arsitektur *Autoencoder* dan MLP.


3) Preprocessing Dataset

Pada tahap *preprocessing*, citra daun *lettuce iceberg* melalui beberapa tahapan pengolahan awal. Pertama, setiap citra diberi label sesuai kategorinya, yaitu *nitrogen deficiency*, *phosphorus deficiency*, *potassium deficiency*, dan *healthy*, sehingga setiap data memiliki identitas kelas yang jelas. Selanjutnya dilakukan segmentasi warna dengan mengonversi citra dari format BGR (*Blue, Green, Red*) ke HSV (*Hue, Saturation, Value*). Model HSV dipilih karena lebih efektif dalam memisahkan objek daun dari latar belakang berdasarkan intensitas warna hijau. Rentang warna hijau ditentukan menggunakan *lower bound* dan *upper bound* HSV untuk membentuk mask yang mempertahankan area daun dan menghilangkan latar belakang.

Citra hasil segmentasi kemudian diubah ukurannya menjadi 128*128 piksel agar seluruh data memiliki resolusi seragam dan sesuai dengan kebutuhan arsitektur model. Selanjutnya dilakukan normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 dengan membagi setiap nilai piksel dengan 255.0, untuk mempercepat konvergensi selama pelatihan model serta menjaga stabilitas perhitungan numerik.

Untuk meningkatkan keragaman data tanpa perlu melakukan pengambilan gambar tambahan, diterapkan teknik augmentasi berupa rotasi, *horizontal flip*, dan *zoom*. Augmentasi ini bertujuan untuk mensimulasikan variasi sudut pengambilan gambar, arah orientasi daun, serta perbedaan jarak kamera sehingga model mampu beradaptasi

terhadap kondisi visual nyata di lapangan. Terakhir, dataset dibagi menjadi dua bagian menggunakan metode *train-test split* dengan proporsi 80% data pelatihan dan 20% data pengujian.



Gambar 7 Hasil Preprocessing.

4) Pelatihan Model *Autoencoder*

Model *autoencoder* dirancang dengan sejumlah hyperparameter yang dioptimalkan untuk menghasilkan rekonstruksi citra daun yang akurat. Model menggunakan learning rate sebesar 0.001 dengan *optimizer adam*, karena kemampuannya dalam menyesuaikan laju pembelajaran secara adaptif terhadap setiap parameter, sehingga proses konvergensi menjadi lebih cepat dan stabil. Fungsi *loss* yang digunakan adalah *binary crossentropy* yang sesuai untuk data citra dengan nilai piksel yang telah dinormalisasi dalam rentang 0–1.

Fungsi aktivasi ReLU diterapkan pada bagian *bottleneck layer* untuk mempercepat proses pembelajaran dan mengurangi risiko *vanishing gradient*, sedangkan aktivasi *sigmoid* digunakan pada *output layer* untuk menghasilkan rekonstruksi citra dengan nilai piksel yang proporsional terhadap skala *input*. Proses pelatihan dilakukan selama 30 *epoch* dengan *batch size* 32.


Untuk menghindari *overfitting*, diterapkan mekanisme *early stopping* yang memantau nilai *validation loss*. Jika tidak terjadi peningkatan performa selama lima *epoch* berturut-turut, pelatihan dihentikan secara otomatis, dan bobot terbaik sebelum penurunan performa akan dipulihkan. Pendekatan ini memastikan model mencapai hasil optimal dan stabil dalam proses rekonstruksi fitur citra daun.

Tabel 2 Hyperparameter *Autoencoder*

| No. | Hyperparameter | Value |
|-----|----------------------|---------------------|
| 1 | Learning Rate | 0.001 |
| 2 | Optimizer | Adam |
| 3 | Loss | Binary Crossentropy |
| 4 | Activation | ReLU |
| 5 | Output | Sigmoid |
| 6 | Train Epoch | 30 |
| 7 | Batch Size | 32 |
| 8 | Callback | EarlyStopping |
| 9 | Monitor | Val_loss |
| 10 | Patience | 5 |
| 11 | Restore Best Weights | True |

Hasil rekonstruksi *autoencoder* menampilkan perbandingan antara citra asli pada baris pertama dan citra hasil rekonstruksi pada baris kedua. Dari hasil tersebut terlihat bahwa struktur utama daun, pola warna hijau, serta bentuk objek utama tetap terjaga, meskipun beberapa detail halus seperti tekstur dan tepi daun mengalami penyederhanaan. Kondisi ini menunjukkan bahwa *autoencoder* mampu menangkap fitur visual yang relevan, seperti gradasi warna,

perbedaan intensitas cahaya, dan kontur objek daun, yang menjadi representasi penting dalam tahap klasifikasi selanjutnya.



Gambar 8 Hasil Ekstraksi *Autoencoder*.

5) Pelatihan Model MLP

Model *Multilayer Perceptron* (MLP) dirancang dengan *learning rate* sebesar 0.001 menggunakan *optimizer adam*, yang mampu menyesuaikan laju pembelajaran secara adaptif guna mempercepat proses konvergensi. Fungsi *loss* yang digunakan adalah *categorical crossentropy*, karena permasalahan ini termasuk klasifikasi multi-kelas. Metrik evaluasi yang dipantau selama pelatihan adalah *accuracy*, yang mengukur tingkat ketepatan prediksi model terhadap label sebenarnya.

Fungsi aktivasi ReLU diterapkan pada setiap *hidden layer* untuk mempercepat pembelajaran dan mengatasi masalah *vanishing gradient*, sedangkan fungsi aktivasi *Softmax* digunakan pada *output layer* untuk menghasilkan distribusi probabilitas pada masing-masing kelas. Pelatihan dilakukan dengan maksimum 25 *epoch* dan *batch size* 32, dengan proses validasi menggunakan data uji (X_{test_enc} , y_{test_cat}) guna memantau kinerja model selama pelatihan.

Untuk mencegah *overfitting*, diterapkan *callback early stopping* yang memantau nilai *validation loss*. Jika tidak terjadi penurunan selama lima *epoch* berturut-turut, proses pelatihan dihentikan secara otomatis, dan opsi *restore best weights* diaktifkan agar model mempertahankan bobot terbaik sebelum performa menurun. Dengan demikian, model MLP mampu mencapai hasil pelatihan yang lebih stabil dan optimal pada data pengujian.


Tabel 3 *Hyperparameter* MLP

| No. | <i>Hyperparameter</i> | <i>Value</i> |
|-----|-----------------------------|-----------------------------------|
| 1 | <i>Learning Rate</i> | 0.001 |
| 2 | <i>Optimizer</i> | Adam |
| 3 | <i>Loss</i> | <i>Categorical Crossentropy</i> |
| 4 | <i>Metrics</i> | <i>Accuracy</i> |
| 5 | <i>Activation</i> | ReLU |
| 6 | <i>Output</i> | <i>Softmax</i> |
| 7 | <i>Train Epoch</i> | 25 |
| 8 | <i>Batch Size</i> | 32 |
| 9 | <i>Validation Data</i> | x_{test_enc} , y_{test_cat} |
| 10 | <i>Callback</i> | <i>EarlyStopping</i> |
| 11 | <i>Monitor</i> | <i>Val_loss</i> |
| 12 | <i>Patience</i> | 5 |
| 13 | <i>Restore Best Weights</i> | True |

Hasil visualisasi prediksi model MLP terhadap beberapa citra daun *lettuce iceberg* menunjukkan dua informasi utama, yaitu *pred* (hasil prediksi model) dan *true* (label sebenarnya). Angka-angka tersebut merepresentasikan kelas yang telah didefinisikan sebelumnya, yaitu *nitrogen deficiency*, *phosphorus deficiency*, *potassium deficiency*, dan

healthy. Label prediksi ditampilkan dengan warna hijau jika hasil klasifikasi sesuai dengan label sebenarnya, sedangkan warna merah menunjukkan kesalahan prediksi.

Dari hasil visualisasi, terlihat bahwa model mampu mengklasifikasikan sebagian besar citra dengan benar, menunjukkan kemampuan generalisasi yang baik. Namun, masih terdapat beberapa kasus kesalahan prediksi yang kemungkinan disebabkan oleh kemiripan pola visual antar kelas atau kompleksitas tekstur daun, terutama pada kelas nitrogen dan fosforus yang memiliki karakteristik warna serupa.



Gambar 9 Hasil Prediksi MLP.

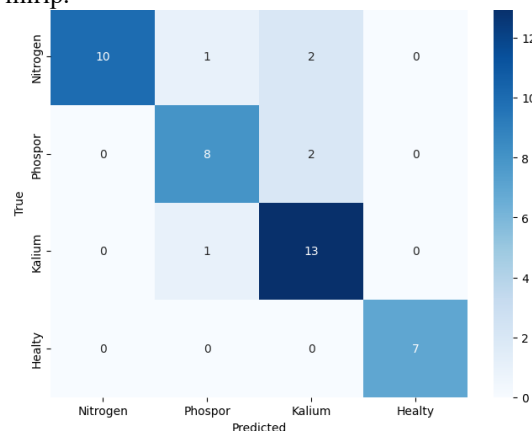
6) Evaluasi Model

a) Confusion matrix model autoencoder dan MLP

Confusion matrix yang dihasilkan menggambarkan performa model MLP dalam mengklasifikasikan empat kelas kondisi daun, yaitu *nitrogen deficiency*, *phosphorus deficiency*, *potassium deficiency*, dan *healthy*. Pada matriks tersebut, setiap baris merepresentasikan label sebenarnya (*true label*), sedangkan setiap kolom menunjukkan label yang diprediksi oleh model.

Berdasarkan hasil evaluasi, kelas *nitrogen* memiliki total 13 data uji dengan 10 citra berhasil diklasifikasikan dengan benar, satu citra salah diklasifikasikan sebagai *phosphorus*, dan dua citra lainnya diklasifikasikan sebagai *potassium*. Pada kelas *phosphorus*, dari 10 citra uji, sebanyak 8 citra diklasifikasikan dengan benar, sementara 2 citra lainnya salah teridentifikasi sebagai *potassium*. Selanjutnya, kelas *potassium* menunjukkan performa yang cukup baik, dengan 13 dari 14 citra berhasil diklasifikasikan secara akurat, dan hanya satu citra yang salah diprediksi sebagai *phosphorus*. Adapun kelas *healthy* memperoleh hasil terbaik, dengan seluruh 7 citra uji berhasil diklasifikasikan dengan benar oleh model.

Secara keseluruhan, hasil ini menunjukkan bahwa model MLP memiliki kemampuan klasifikasi yang baik, khususnya pada kelas *healthy* dan *potassium deficiency*. Kesalahan klasifikasi yang terjadi umumnya disebabkan oleh kemiripan visual antar kelas defisiensi nutrisi, terutama antara kelas *nitrogen* dan *phosphorus*, yang memiliki gradasi warna daun dan pola kerusakan yang mirip.



Gambar 10 Confusion Matrix Autoencoder + MLP.


b) *Confusion matrix model baseline MLP*

Confusion matrix yang dihasilkan menunjukkan performa model *baseline MLP* dalam mengklasifikasikan empat kelas kondisi daun *lettuce*: *Nitrogen*, *Phosphor*, Kalium, dan *Healthy*. Pada kelas *Nitrogen*, terdapat 13 sampel pengujian, dan model berhasil mengklasifikasikan 8 di antaranya dengan benar. Namun, 3 sampel salah diklasifikasikan sebagai *Phosphor* dan 2 sampel salah diprediksi sebagai Kalium.

Untuk kelas *Phosphor*, model mengklasifikasikan 6 dari 10 sampel dengan benar, sementara 4 sampel lainnya salah diprediksi sebagai Kalium, menunjukkan bahwa model sering mengalami kebingungan dalam membedakan gejala kekurangan fosfor dengan kalium. Pada kelas Kalium, performa model cukup baik, dengan 13 dari 14 sampel berhasil diprediksi secara akurat. Hanya 1 sampel yang salah diprediksi sebagai *Phosphor*.

Sementara itu, untuk kelas *Healthy*, model menunjukkan performa yang rendah, dengan hanya 4 dari 7 sampel yang diklasifikasikan dengan benar. Sebanyak 3 sampel lainnya salah diklasifikasikan sebagai Kalium, yang mengindikasikan bahwa kondisi daun sehat cenderung memiliki kemiripan pola visual dengan daun yang mengalami kekurangan kalium.

Secara keseluruhan, *confusion matrix* ini menunjukkan bahwa *baseline MLP* memiliki kecenderungan keliru dalam membedakan kelas *Phosphor* dan *Healthy* terhadap kelas Kalium, serta belum mampu menangkap fitur visual secara optimal tanpa proses ekstraksi fitur dari *autoencoder*.

Gambar 11 *Confusion Matrix Baseline MLP*.

c) Perbandingan Evaluasi Model

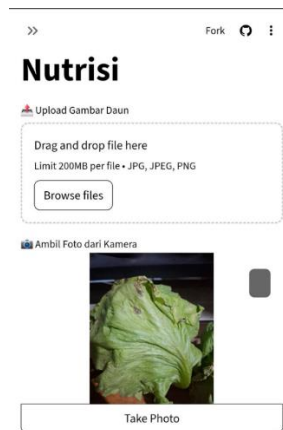
Tabel 4 Evaluasi Model

| Model | Akurasi | Presisi | Recall | F1-Score |
|--------------------------|---------|---------|--------|----------|
| Autoencoder + MLP | 0.86 | 0.89 | 0.87 | 0.88 |
| MLP Baseline | 0.70 | 0.80 | 0.68 | 0.70 |

Hasil perbandingan evaluasi pada tabel 4 menunjukkan bahwa model *autoencoder* dan MLP memiliki performa yang lebih unggul dibandingkan model *MLP Baseline* pada seluruh metrik evaluasi. Model *autoencoder* dan MLP mencapai akurasi sebesar 0.86, presisi 0.89, *recall* 0.87, dan *F1-Score* 0.88, yang menandakan kemampuan klasifikasi yang stabil dan konsisten pada keempat kelas defisiensi nutrisi. Sementara itu, model *MLP Baseline* hanya memperoleh akurasi 0.70, presisi 0.80, *recall* 0.68, dan *F1-Score* 0.70, menunjukkan bahwa kinerja model tanpa proses ekstraksi fitur masih terbatas, terutama dalam mengenali pola visual yang kompleks pada citra daun.

Perbedaan hasil ini menegaskan bahwa penggunaan *autoencoder* sebagai tahap ekstraksi fitur mampu meningkatkan kualitas representasi data dan membantu MLP dalam melakukan klasifikasi dengan lebih efektif. Dengan demikian, integrasi *autoencoder* dan MLP terbukti memberikan kontribusi signifikan dalam meningkatkan performa sistem deteksi kekurangan nutrisi pada tanaman *lettuce iceberg* dibandingkan model *baseline* yang hanya menggunakan MLP.

7) Hasil Implementasi *Streamlit*



Gambar 12 Hasil Implementasi Sebelum *Capture* Gambar.

Tampilan *streamlit* sebelum *upload* gambar dari aplikasi deteksi kekurangan nutrisi. Tampilan ini menunjukkan halaman utama aplikasi yang memfasilitasi pengguna untuk mengunggah gambar daun atau *capture* gambar yang akan dianalisis. Fitur utama pada halaman ini adalah komponen *file uploader*, di mana pengguna dapat melakukan "*drag and drop*", memilih *file* gambar secara manual menggunakan tombol *browse files*, atau men-*capture* secara langsung. Sistem ini mendukung format *file* gambar seperti JPG, PNG, dan JPEG, dengan batas ukuran maksimum 200MB per gambar, memungkinkan fleksibilitas dalam proses *input* data.



Gambar 13 Hasil Implementasi Setelah *Capture* Gambar.

Tampilan hasil akhir dari antarmuka pengguna aplikasi berbasis *streamlit* yang dikembangkan untuk mendeteksi kekurangan nutrisi pada daun *lettuce iceberg*. Setelah pengguna mengunggah gambar daun melalui tampilan awal aplikasi, sistem secara otomatis akan memproses citra tersebut menggunakan *work flow* model yang telah dibangun, yang terdiri dari proses *preprocessing*, ekstraksi fitur menggunakan *autoencoder*, dan klasifikasi menggunakan *Multilayer Perceptron* (MLP).

Berdasarkan hasil prediksi gambar, sistem mendeteksi bahwa kondisi tanaman yang dianalisis memiliki kemungkinan tertinggi mengalami kekurangan kalium dengan tingkat kepercayaan sebesar 54,91%. Selain itu, persentase untuk kelas lainnya menunjukkan bahwa tanaman ini memiliki kemungkinan 16,90% mengalami kekurangan nitrogen, 18,03% mengalami kekurangan fosfor, dan 10,15% dalam kondisi sehat.

4. DISCUSSION

Implementasi sistem deteksi kekurangan nutrisi pada daun *lettuce iceberg* menggunakan kombinasi *autoencoder* dan *Multilayer Perceptron* (MLP) telah berhasil direalisasikan dengan baik. Sistem ini mampu memproses citra daun secara otomatis mulai dari tahap *preprocessing*, ekstraksi fitur, hingga menghasilkan prediksi jenis defisiensi nutrisi yang dialami tanaman. Model *autoencoder* terbukti efektif dalam menangkap fitur-fitur penting

dari citra daun, sedangkan MLP berperan optimal dalam mengklasifikasikan hasil ekstraksi fitur ke dalam empat kategori utama defisiensi nutrisi.

Hasil pengujian menunjukkan performa yang memuaskan, dengan akurasi sebesar 86%, presisi 89%, *recall* 87%, dan *F1-score* 88%. Nilai metrik tersebut menunjukkan bahwa sistem memiliki kemampuan generalisasi yang baik terhadap data uji, sehingga dapat diandalkan untuk mengklasifikasikan citra daun yang belum pernah dilihat sebelumnya.

Dari sisi antarmuka, integrasi sistem dengan *platform streamlit* memberikan keunggulan dalam hal kemudahan akses dan interaktivitas. Aplikasi berbasis *web* ini memungkinkan pengguna untuk mengunggah citra daun dan memperoleh hasil klasifikasi secara *real-time* melalui *browser*, baik di perangkat *desktop* maupun *mobile*, tanpa memerlukan instalasi tambahan. Antarmuka yang ringan dan intuitif menjadikan sistem ini mudah digunakan oleh berbagai kalangan, termasuk petani, peneliti, maupun praktisi pertanian.

Secara keseluruhan, sistem yang dikembangkan telah memenuhi tujuan penelitian, yaitu menyediakan alat bantu berbasis kecerdasan buatan yang mampu mendeteksi kekurangan nutrisi tanaman secara otomatis, akurat, dan efisien. Untuk pengembangan selanjutnya, disarankan dilakukan perluasan dan peningkatan variasi dataset, terutama dalam hal pencahayaan, sudut pengambilan gambar, serta kondisi daun yang lebih beragam.

5. CONCLUSION

Sistem yang dikembangkan menunjukkan performa klasifikasi yang baik, dengan tingkat akurasi sebesar 86%, presisi 89%, *recall* 87%, dan *F1-score* 88%, yang menandakan bahwa model mampu memprediksi jenis kekurangan nutrisi dengan tingkat ketepatan dan konsistensi yang tinggi. Hasil ini diperoleh dari proses pelatihan menggunakan 147 citra daun dan pengujian sebanyak 36 citra daun, yang masing-masing mewakili kondisi dari setiap kelas defisiensi nutrisi.

Selain itu, sistem telah berhasil diintegrasikan dengan antarmuka pengguna berbasis *streamlit*, yang memungkinkan pengguna untuk mengunggah citra daun dan memperoleh hasil klasifikasi secara *real-time* langsung melalui *browser*. Aplikasi ini dapat dijalankan pada perangkat *desktop* maupun *mobile* tanpa memerlukan instalasi tambahan, sehingga menjadikannya ringan, interaktif, dan mudah digunakan oleh pengguna dari berbagai kalangan.

6. REFERENCE

- [1] J. Hong *dkk.*, “Evaluation of the Effects of Nitrogen, Phosphorus, and Potassium Applications on the Growth, Yield, and Quality of Lettuce (*Lactuca sativa* L.),” *Agronomy*, vol. 12, no. 10, 2022, doi: 10.3390/agronomy12102477.
- [2] K. Vought *dkk.*, “Dynamics of micro and macronutrients in a hydroponic nutrient film technique system under lettuce cultivation,” *Heliyon*, vol. 10, no. 11, hal. e32316, 2024, doi: 10.1016/j.heliyon.2024.e32316.
- [3] D. Armita, W. Wahdaniyah, H. Hafsan, dan H. Al Amanah, “Diagnosis Visual Masalah Unsur Hara Esensial Pada Berbagai Jenis Tanaman,” *Teknosains Media Inf. Sains dan Teknol.*, vol. 16, no. 1, hal. 139–150, 2022, doi: 10.24252/teknosains.v16i1.28639.
- [4] J. Xie, S. Lv, X. Zhang, W. Song, X. Liu, dan Y. Lu, “Exploring Nutrient Deficiencies in Lettuce Crops: Utilizing Advanced Multidimensional Image Analysis for Precision Diagnosis,” *Sensors*, vol. 25, no. 7, 2025, doi: 10.3390/s25071957.
- [5] D. A. P. Oktavia, S. Rizal, dan N. K. C. Pratiwi, “Klasifikasi Gejala Defisiensi Nutrisi Pada Tanaman Padi Menggunakan CNN Dengan Arsitektur Resnet-50,” *e-Proceeding Eng.*, vol. 8, no. 6, hal. 3171–3175, 2022.
- [6] P. Bedi, P. Gole, dan S. Marwaha, “PDSE-Lite: lightweight framework for plant disease severity estimation based on Convolutional Autoencoder and Few-Shot Learning,” *Front. Plant Sci.*, vol. 14, no. January, hal. 1–20, 2023, doi: 10.3389/fpls.2023.1319894.
- [7] U. naz dan M. M. Malik, “A Comprehensive Review of Plant Disease Detection Using Deep Learning,” *Univ. Wah J. Comput. Sci.*, vol. 5, hal. 1–12, 2023.
- [8] S. Kolhar, J. Jagtap, dan R. Shastri, “Deep Neural Networks for Classifying Nutrient Deficiencies in Rice Plants Using Leaf Images,” *Int. J. Comput. Digit. Syst.*, vol. 16, no. 1, hal. 305–314, 2024, doi: 10.12785/ijcds/160124.
- [9] I. Pacal *dkk.*, “A systematic review of deep learning techniques for plant diseases,” *Artif. Intell. Rev.*, vol. 57, no. 11, 2024, doi: 10.1007/s10462-024-10944-7.
- [10] J. Sikati dan J. C. Nouaze, “YOLO-NPK: A Lightweight Deep Network for Lettuce Nutrient Deficiency Classification Based on Improved YOLOv8 Nano †,” *Eng. Proc.*, vol. 58, no. 1, hal. 0–7, 2023, doi:

- 10.3390/ecsa-10-16256.
- [11] D. Djidonou dan D. I. Leskovar, “Seasonal changes in growth, nitrogen nutrition, and yield of hydroponic lettuce,” *HortScience*, vol. 54, no. 1, hal. 76–85, 2019, doi: 10.21273/HORTSCI13567-18.
 - [12] P. Pandey, P. Veazie, B. Whipker, dan S. Young, “Predicting foliar nutrient concentrations and nutrient deficiencies of hydroponic lettuce using hyperspectral imaging,” *Biosyst. Eng.*, vol. 230, hal. 458–469, 2023, doi: 10.1016/j.biosystemseng.2023.05.005.
 - [13] M. F. Taha *dkk.*, “Using Deep Convolutional Neural Network for Image-Based Diagnosis of Nutrient Deficiencies in Plants Grown in Aquaponics,” *Chemosensors*, vol. 10, no. 2, hal. 1–23, 2022, doi: 10.3390/chemosensors10020045.
 - [14] J. Kusuma, Rubianto, R. Rosnelly, Hartono, dan B. H. Hayadi, “Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron,” *J. Appl. Comput. Sci. Technol.*, vol. 4, no. 1, hal. 1–6, 2023, doi: 10.52158/jacost.v4i1.484.
 - [15] S. Natarajan, P. Chakrabarti, dan M. Margala, “Robust diagnosis and meta visualizations of plant diseases through deep neural architecture with explainable AI,” *Sci. Rep.*, vol. 14, no. 1, hal. 1–14, 2024, doi: 10.1038/s41598-024-64601-8.

7. AUTHORS

Sadra Muhammad merupakan mahasiswa Program Studi Teknik Informatika di Universitas Islam Sultan Agung, Semarang. Minat penelitiannya meliputi bidang Kecerdasan Buatan, Pembelajaran Mesin, dan Pengembangan Aplikasi Web. Ia memiliki pengalaman dalam pengembangan perangkat lunak serta pernah mengikuti program Studi Independen Bersertifikat dengan fokus pada Fullstack Web Development. Email: sadraazizi1305@gmail.com.

Sam Farisa Chaerul Haviana merupakan dosen di Universitas Islam Sultan Agung, Semarang. Fokus penelitiannya meliputi *Machine Learning*, *Data Mining*, dan *Natural Language Processing (NLP)*, dengan ketertarikan pada pengembangan dan penerapan metode kecerdasan buatan untuk pemecahan masalah berbasis data. Email: sam@unissula.ac.id.