

Klasifikasi Gejala Defisiensi Nutrisi Pada Tanaman Padi Menggunakan CNN Dengan Arsitektur Resnet-50

1st Deva Aulia Putri Oktavia

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

devaaulia@student.telkomuniversity.ac.id

2nd Syamsul Rizal

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

syamsulrizal@telkomuniversity.ac.id

3rd Nor Kumalasari Caecar Pratiwi

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

caecarnkcp@telkomuniversity.ac.id

Abstrak

Tanaman padi merupakan komoditas tanaman

pangan utama di Indonesia, karena padi menghasilkan beras yang merupakan makanan pokok bagi sebagian besar masyarakat Indonesia. Produksi padi di Indonesia sendiri pada tahun 2022 mengalami penurunan dari tahun sebelumnya. Defisiensi nutrisi dapat menjadi salah satu penyebab petani mengalami gagal panen. Untuk menghindari terjadinya defisiensi nutrisi pada tanaman padi, petani disarankan untuk melakukan deteksi dini untuk menghindari terjadinya defisiensi nutrisi pada tanaman padi. Berdasarkan hal tersebut maka pada penelitian ini akan dilakukan pengklasifikasian defisiensi nutrisi yang terbagi menjadi 3 kelas makro nutrisi yaitu, Nitrogen (N), Fosfor (P), dan Kalium (K) menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50 dan ResNet-152. Dataset yang digunakan bersumber dari Kaggle yang berisi 1156 citra tanaman padi yang mengalami defisiensi nutrisi. Parameter performans yang akan dianalisis pada penelitian ini adalah *Confusion Matrix*, akurasi, presisi, *recall* dan *F1-Score* untuk mengukur kinerja sistem yang telah dirancang. Terdapat empat skenario pengujian terhadap *hyperparameter* berupa *optimizer*, *learning rate*, *batch size* dan *input size* yang dilakukan pada citra asli dan citra hasil CLAHE. Hasil terbaik dari penelitian ini didapatkan dari kombinasi *hyperparameter* berupa *optimizer* Adam, *learning rate* 0.001, *batch size* 64 dan *input size* 512×512 piksel dengan citra CLAHE. Dari kombinasi *hyperparameter* tersebut dihasilkan akurasi sebesar 97,73%.

Kata Kunci: Defisiensi Nutrisi, Tanaman Padi, CNN, ResNet, Klasifikasi.

Abstract

Rice plant is the main food crop commodity in

Indonesia, rice is staple food for most of Indonesia. Rice production in Indonesia itself in 2022 decreased from the previous year. Nutritional deficiency can be one of the causes of farmers failing to harvest. Because plants need the right combination of nutrients to grow properly. To avoid deficiency in rice plants, farmers are advised to carry out early detection to avoid deficiencies in rice plants. Based on this, this study will classify nutritional deficiencies which are divided into 3 macronutrient classes, namely, Nitrogen (N), Phosphorus (P), and Potassium (K) using *Convolutional Neural Network* (CNN) with ResNet-50 and ResNet-152 architectures. The dataset used is sourced from Kaggle which contains 1156 images of rice plants that are nutritionally deficient. The performance parameters that will be analyzed in this study are *Confusion Matrix*, accuracy, precision, recall and *F1-Score* to measure the performance of the system that has been designed. There are four test scenarios for hyperparameters in the form of optimizer, learning rate, batch size and input size which are carried out on the original image and the CLAHE image. The best results from this study were obtained from a combination of hyperparameters in the form of Adam optimizer, learning rate 0.001, batch size 64 and input size 512×512 pixels with CLAHE images. From the combination of these hyperparameters, an accuracy of 97.73%.

Keywords: Nutritional Deficiency, Rice Plant, CNN, ResNet, Classification

I. PENDAHULUAN

Tanaman padi (*Oryza sativa* L.) adalah komoditas tanaman pangan penting di Indonesia, karena beras merupakan makanan pokok masyarakat Indonesia. Beras merupakan makanan pokok yang sulit digantikan

oleh sumber karbohidrat lainnya seperti umbi-umbian, sagu, jagung, dan lain-lain. Karena beras mengandung gizi yang lebih baik bila dibandingkan dengan makanan pokok lainnya. Menurut data statistik BPS tahun 2021

produksi padi di Indonesia mengalami penurunan sekitar 0,43% bila dibandingkan dengan produksi padi pada tahun 2020 [1]. Penurunan angka produksi padi pun tidak luput dari pengaruh unsur hara atau nutrisi tanaman seperti Nitrogen (N), Fosfor (P), dan Kalium (K). Unsur hara tersebut didapatkan oleh tanaman melalui pupuk. Praktik pemupukan yang tidak ilmiah dapat mengakibatkan nutrisi yang tidak seimbang pada tanaman [2]. Apabila tanaman mengalami kekurangan unsur hara atau nutrisi penting seperti Nitrogen (N), Fosfor (P) dan Kalium (K), hal tersebut dapat mempengaruhi pertumbuhan secara signifikan [3] yang dapat menyebabkan kerugian bagi para petani karena kualitas produksi tanaman padi yang menurun. Untuk mencegah terjadinya gagal panen diakibatkan oleh defisiensi nutrisi perlu dilakukan klasifikasi defisiensi nutrisi pada tanaman padi.

II. KAJIAN TEORI


Pada penelitian sebelumnya yang dilakukan oleh Zhe Xu, Xi Guo, Anfan Zhu, Xiaolin He, Xiaomin Zhao, Yi Han, dan Roshan Subedi, yang mengusulkan penggunaan *Deep Convolutional Neural Network* (DCNN) dengan arsitektur Inception-v3, ResNet50 layers, NasNet-Large, Dense121 layers untuk mendeteksi adanya defisiensi nutrisi pada tanaman padi yang memiliki tingkat akurasi mencapai 90% dan arsitektur DenseNet121 memiliki performa terbaik dengan akurasi validasi sebesar 98,62% dan akurasi pengujian sebesar 97,44% [2]. Penelitian lainnya dilakukan oleh Arief Rais Bahtiar, Pranowo, Albertus Joko Santoso dan Jujuk Juhariah yang membahas mengenai pendeteksian defisiensi nutrisi pada tanaman cabai menggunakan *Deep Learning*. Dari hasil penelitian yang menggunakan algoritma RCNN sebagai arsitektur untuk sistemnya diperoleh hasil akurasi pengujian tertinggi sebesar 82,61% dengan nilai mAP terbaik sebesar 15,57% [5]. Selain itu penelitian lain juga dilakukan oleh Choi Jae-Won dan teman-teman, mengusulkan tentang metode prediksi defisiensi nutrisi pada pertumbuhan tanaman tomat menggunakan *Deep Learning*. Dari hasil penelitian menggunakan Inception-ResNet v2 didapatkan hasil akurasi pengujian keseluruhan mencapai 92% dan akurasi validasi sebesar 87,5% [6].

III. METODE

A. Convolutional Neural Network

Convolutional Neural Network (CNN) atau bisa disebut dengan ConvNet adalah algoritma *Deep Learning* yang mengambil gambar sebagai input, lalu menetapkan bias dan bobot untuk berbagai objek dalam gambar dan mampu membedakan objek satu sama lain. Proses pra-pemrosesan yang diperlukan oleh CNN lebih rendah bila dibandingkan dengan algoritma klasifikasi lainnya [7]. CNN sendiri adalah bentuk pengembangan dari *Multilayer Perceptron* (MLP), dimana pada CNN setiap neuron dipresentasikan dalam bentuk dua dimensi sedangkan pada MLP setiap neuronnya dipresentasikan

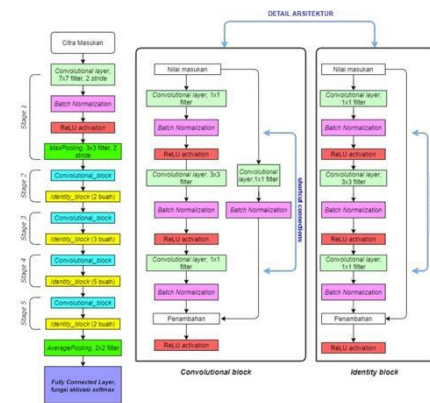
dalam bentuk satu dimensi [8]. Arsitektur CNN terdiri dari dua bagian yaitu *Feature Learning* dan *Classification*. Bagian feature learning terbagi ke dalam tiga lapisan yaitu *Convolutional Layer*, *Rectified Linear Unit* (ReLU) *Activation Layer*, dan *Pooling layer*. Sedangkan pada bagian *Classification* tahapannya terbagi menjadi *Flatten layer*, *Fully Connected Layer* dan *Softmax*.



GAMBAR 1 Arsitektur CNN

1. ResNet-50

Konsep baru yang bernama shortcut connections pertama kali diperkenalkan di ResNet-50. Konsep *shortcut connections* yang ada pada ResNet-50 berkaitan dengan *vanishing gradient problem* yang dapat terjadi ketika memperdalam struktur suatu jaringan. Tujuan dari memperdalam suatu jaringan adalah untuk meningkatkan performa dari jaringan tersebut, namun tidak bisa dilakukan dengan cara menumpuk layer. Apabila kita membuat jaringan yang semakin dalam dapat memunculkan *vanishing gradient problem* yang dapat membuat gradient menjadi kecil sehingga menurunkan performansi atau akurasi dari jaringan tersebut [9].

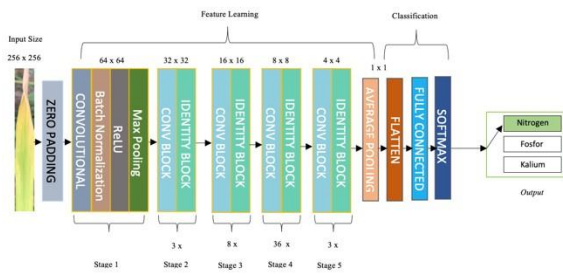


GAMBAR 2 Arsitektur ResNet-50

2. ResNet-152

Resnet-152 adalah layer kelima dari arsitektur ResNet yang memiliki 152 lapisan. Pada setiap layer yang ada di arsitektur resnet memiliki jumlah konvolusi yang berbeda. Di arsitektur ResNet-152 tahap pertama yang dilakukan adalah konvolusi 7x7 yang memiliki filter sebanyak 64 dan 2 stride, tahap kedua yang dilakukan adalah *max pooling* dengan ukuran matriks 3x3 dan 2 stride, tahap ketiga yang dilakukan adalah konvolusi dengan matriks ukuran 1x1 yang berjumlah 64 filter, matriks ukuran 3x3 yang berjumlah 64 filter,

matriks ukuran 1x1 dengan filter berjumlah 256, tahap ini dilakukan secara berulang sebanyak tiga kali.



GAMBAR 3 Arsitektur ResNet-152

B. Parameter Pengujian performansi

Tahapan evaluasi dalam pengklasifikasian jenis kendaraan dengan *deep learning* menggunakan CNN memerlukan beberapa pengujian.

1. Akurasi

Akurasi merupakan parameter yang membandingkan antara nilai prediksi dan nilai aktual. Parameter akurasi dapat menunjukkan tingkat efektifitas per kelas dari sebuah klasifikasi [10].

$$\text{Akurasi} = \frac{(TP + TN)}{TP + FP + FN + TN} \times 100\% \quad (1)$$

2. Presisi

Presisi adalah parameter yang menentukan tingkat keakuratan antara informasi yang diminta oleh user dengan jawaban yang diberikan oleh sistem. Presisi memberikan hasil dalam bentuk persen bagaimana sistem mengklasifikasi kelas yang benar dari klasifikasi yang diprediksi kelas yang benar [11].

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

3. Recall

Recall adalah parameter yang mengukur kemampuan sistem untuk mendeteksi nilai positif [10].

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

4. F1 Score

F1-Score adalah nilai kombinasi yang diambil dari perhitungan *recall* dan presisi [10].

$$\text{F1-Score} = 2 \times \frac{\frac{TP}{TP + FP} \times \frac{TP}{TP + FN}}{\frac{TP}{TP + FP} + \frac{TP}{TP + FN}} \times 100\% \quad (4)$$

C. Dataset

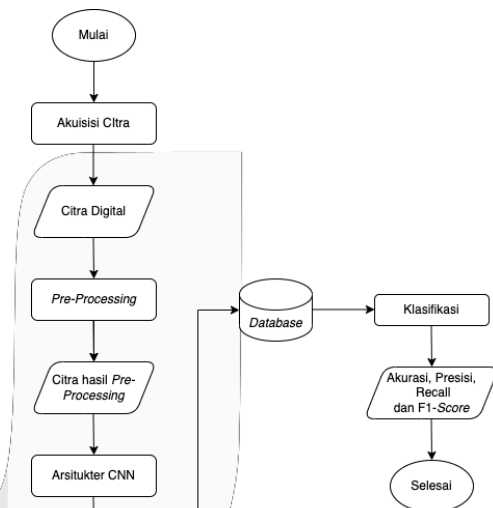
Dataset yang digunakan pada penelitian ini merupakan dataset bersumber dari Kaggle [11]. Dataset ini berisi citra defisiensi nutrisi pada tanaman padi dari 3 kelas berbeda yaitu Nitrogen (N) yang berjumlah 440 citra, Fosfor (P) yang berjumlah 333 citra dan Kalium (K) yang berjumlah 383 citra. Dataset yang digunakan dalam penelitian ini terdiri dari 1156 citra dengan resolusi 300 dpi, format .jpg dan RGB. Citra tersebut diambil menggunakan kamera iPhone 11 dengan konfigurasi yaitu ISO Speed 64, dan *Exposure time* 1/120 second.



GAMBAR 4 (a) Nitrogen, (b) fosfor, (c) Kalium

D. Desain Sistem

Pada penelitian ini dirancang sistem untuk mengklasifikasi defisiensi nutrisi yang terdiri dari tiga kelas yaitu defisiensi Nitrogen (N), Fosfor (P), Kalium (K) menggunakan algoritma CNN dengan arsitektur ResNet-50 dan ResNet-152. Alur kerja pada sistem ini dapat dilihat dari diagram alir sebagai berikut.



GAMBAR 5 Diagram Alir Pengujian Sistem


Terdapat tiga langkah utama yang dilakukan sebelum proses pelatihan, dan pengujian data yaitu akuisisi citra yang merupakan proses pengumpulan dataset yang diambil dari Kaggle selanjutnya pre-processing adalah proses persiapan data mentah agar siap untuk diolah oleh sistem dan terakhir pemodelan dengan arsitektur CNN yaitu ResNet-50 dan ResNet-152.

IV. HASIL DAN PEMBAHASAN

Bab ini berisi hasil pengujian sistem yang telah dilakukan untuk mengklasifikasikan defisiensi nutrisi pada tanaman padi menggunakan metode CNN dengan arsitektur ResNet-50 dan ResNet-152. Serta analisis berdasarkan parameter akurasi dan loss yang telah dilakukan berdasarkan empat skenario pengujian.

A. Hasil Pengujian ResNet-50

Model pertama yang digunakan dalam penelitian ini adalah ResNet-50 yang diterapkan pada data asli dan data hasil CLAHE serta menggunakan empat skenario. Gambar 6 menunjukkan grafik akurasi dan loss hasil terbaik yang diperoleh arsitektur ResNet-50.



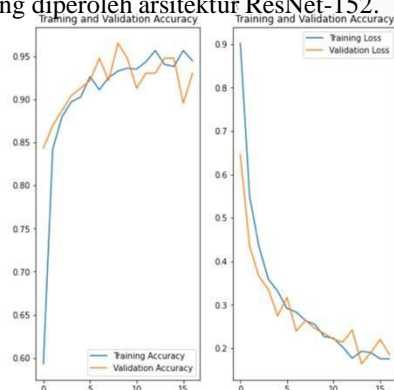
GAMBAR 6 Grafik Hasil Pengujian ResNet-50

Seperti yang tercantum pada Gambar 6, akurasi dan loss dari model terbaik mencapai 96,52%. Nilai ini dicapai ketika pengujian dilakukan menggunakan data citra hasil CLAHE dengan rincian kombinasi hyperparameter sebagai berikut:

1. Optimizer: Adam
2. Learning Rate: 0,001
3. Batch Size: 64
4. Input Size: 512×512 pixels

B. Hasil Pengujian ResNet-152

Model kedua yang digunakan dalam tugas akhir ini adalah ResNet-152 yang diterapkan pada data citra asli dan data hasil CLAHE serta menggunakan empat skenario. Gambar 7 menunjukkan grafik akurasi dan loss hasil terbaik yang diperoleh arsitektur ResNet-152.



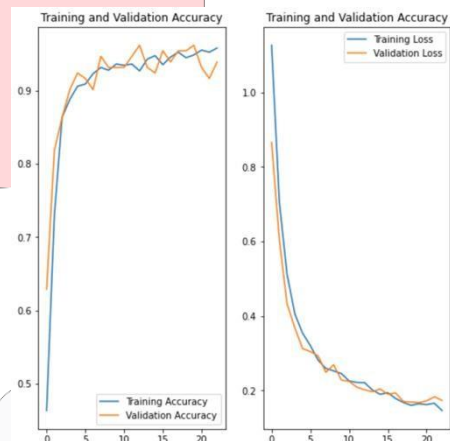
GAMBAR 7 Grafik Hasil Pengujian ResNet-152

Seperti yang tercantum pada gambar 7, akurasi dari model terbaik mencapai 94,48% ini dicapai ketika pengujian dilakukan menggunakan data dengan tambahan preprocessing CLAHE dengan rincian kombinasi hyperparameter sebagai berikut:

1. Optimizer: Adam
2. Learning Rate: 0,001
3. Batch Size: 32
4. Input Size: 512×512 pixels


C. Hasil Pengujian Terbaik

Dari hasil terbsik yang diperoleh kedua arsitektur tadi, dapat dianalisis bahwa arsitektur ResNet-50 dapat mencapai akurasi yang lebih tinggi. Namun, dua pengujian sebelumnya dilakukan menggunakan data unbalance. Percobaan selanjutnya yaitu menguji kombinasi hyperparameter terbaik dari ResNet-50 dengan data balance. Hasil grafik akurasi dan loss dari data balance dapat dilihat pada gambar 8



GAMBAR 8 Grafik Hasil pengujian terbaik

Seperti yang tercantum pada gambar 8, akurasi dari model terbaik mencapai 97,73%. Sehingga dapat disimpulkan bahwa hasil pengujian dengan data citra hasil preprocessing CLAHE menggunakan arsitektur ResNet-50 dengan data balance lebih baik pada penelitian ini. Gambar 9 menunjukkan hasil dari confusion matrix.



GAMBAR 9 Confusion Matrix

V. KESIMPULAN

Penelitian ini telah mengusulkan sistem klasifikasi defisiensi nutrisi pada tanaman padi dengan metode Convolutional Neural Network menggunakan arsitektur ResNet-50 dan ResNet-152 untuk mendapatkan akurasi

yang tinggi dengan nilai loss yang relative rendah. Berdasarkan hasil simulasi dan pengujian sistem, diperoleh beberapa kesimpulan diantaranya sebagai berikut:

- A. Sistem yang dibuat pada tugas akhir ini sudah dapat mengklasifikasikan defisiensi nutrisi pada tanaman padi kedalam tiga kelas yaitu Nitrogen (N), Fosfor (P). dan Potassium (K) dengan akurasi yang cukup tinggi.
- B. Akurasi tertinggi diperoleh dengan menggunakan arsitektur ResNet-50 dengan pre-processing CLAHE serta kombinasi hyperparameter sebagai berikut, optimizer Adam, learning rate 0.001, batch size 32 dan input size 512×512 piksel dengan nilai akurasi sebesar 97,73%.

REFERENSI

- [1] BPS, "Luas Panen dan Produksi Padi di Indonesia 2021 (Angka Tetap)," Ber. Resmi Stat., vol. 2021, no. 77, pp. 1–14, 2021.
- [2] Z. Xu et al., "Using deep convolutional neural networks for image-based diagnosis of nutrient deficiencies in rice," *Comput. Intell. Neurosci.*, vol. 2020, 2020.
- [3] V. Kusanur and V. S. Chakravarthi, "Using Transfer Learning for Nutrient Deficiency Prediction and Classification in Tomato Plant," *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 10, pp. 784–790, 2021.
- [4] L. A. Wulandhari et al., "Plant nutrient deficiency detection using deep convolutional neural network," *ICIC Express Lett.*, vol. 13, no. 10, pp. 971–977, 2019.
- [5] A. R. Bahtiar, Pranowo, A. J. Santoso, and J. Juhariah, "Deep Learning Detected Nutrient Deficiency in Chili Plant," 2020 8th Int. Conf. Inf. Commun. Technol. ICICT 2020, 2020.
- [6] C. Jae-Won, T. T. Trung, T. Le Huynh Thien, P. Geon-Soo, C. Van Dang, and K. Jong-Wook, "A nutrient deficiency prediction method using deep learning on development of tomato fruits," *iFUZZY 2018 - 2018 Int. Conf. Fuzzy Theory Its Appl.*, no. 10062368, pp. 338–341, 2018.
- [7] A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti, and D. De, *Fundamental concepts of convolutional neural network*, vol. 172, January, 2019.
- [8] Y. N. Fu'adah, N. C. Pratiwi, M. A. Pramudito, and N. Ibrahim, "Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 982, no. 1, 2020.
- [9] F. Nashrullah, S. Adhi, and G. Budiman, "Investigasi Parameter Epoch Pada Arsitektur ResNet- 50 Untuk Klasifikasi Pornografi," *J. Comput. Electron. Telecommun.*, pp. 1–8, 2020.
- [10] W. Raksarikon, "Nutrient-Deficiency-Symptoms-in-Rice – Kaggle." [Online]. Available: <https://www.kaggle.com/guy007/nutrientdeficie ncysymptomsinrice>.

- [11] F. Bashir-Gonbadi and H. Khotanlou, "Brain tumor classification using deep convolutional autoencoder-based neural network: multi-task approach," *Multimed. Tools Appl.*, vol. 80, no. 13, pp. 19909–19929, 2021.