

PEMILIHAN HYPERPARAMETER PADA ALEXNET CNN UNTUK KLASIFIKASI CITRA PENYAKIT KEDELAI

Luban Abdi Susanto

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Jember

Jl. Karimata No.49, Jember, Jawa Timur

e-mail: lubanabdi9@gmail.com¹⁾

(Naskah masuk : 12 April 2023 Diterima untuk diterbitkan : 16 Oktober 2023)

ABSTRAK

Kedelai merupakan makanan yang populer. Estimasi hasil di Indonesia berkisar antara 1,2 dan 1,5 ton per hektar, masih jauh di bawah potensi hasil sebesar 2 hingga 2,5 ton per hektar. Gangguan penyakit pada tanaman kedelai merupakan salah satu penyebab rendahnya hasil, sehingga petani harus mengenal penyakit yang menyerang kedelai agar dapat memilih jenis penyakit dan tindakan pengobatan yang tepat. Proses laboratorium pendampingan penyakit masih belum efisien sehingga membutuhkan waktu yang lama. *Computer vision* dan pembelajaran mendalam sekarang dapat digunakan untuk mengenali informasi prediktif pada objek, meskipun objek diposisikan di mana pun objek tersebut dimasukkan. *Convolutional Neural Network* (CNN) adalah teknik pembelajaran mendalam yang paling sering digunakan saat ini. Penelitian ini menggunakan arsitektur CNN yakni AlexNet dengan *hyperparameter tuning* untuk mengklasifikasikan citra penyakit kedelai. *Hyperparameter tuning* sangat berpengaruh terhadap performa model. Dataset yang digunakan berjumlah 1.500 citra penyakit pada daun kedelai, terdiri dari 3 kelas yakni *caterpillar*, *diabrotica speciosa*, dan *healthy*. *Hyperparameter tuning* pada AlexNet CNN dengan ukuran *batch size* 12, *dropout* 0.2, *optimizer* Adam menghasilkan hasil terbaik dari segi nilai akurasi 84%, presisi 81,95%, *recall* 80,66%, serta *f1-score* 80,96%.

Kata Kunci: AlexNet, Convolutional Neural Network, Hyperparameter, Kedelai, Klasifikasi.

ABSTRACT

Soybeans are a popular food. Yield estimates in Indonesia range between 1.2 and 1.5 tons per hectare, still far below the yield potential of 2 to 2.5 tons per hectare. Disease disorders in soybean plants is one of the causes of low yields, so farmers must be familiar with diseases that attack soybeans so they can choose the type of disease and appropriate treatment measures. The laboratory process for disease assistance is still inefficient, so it takes a long time. Computer vision and deep learning can now be used to recognize predictive information on objects, even if the object states wherever it is entered. Convolutional Neural Networks (CNNs) are the most frequently used deep learning technique today. This study uses the CNN architecture, namely AlexNet with hyperparameter tuning to classify soybean disease images. Hyperparameter settings greatly affect the performance of the model. The dataset used amounted to 1,500 disease images on soybean leaves, consisting of 3 classes namely caterpillar, diabrotica speciosa, and healthy. Hyperparameter tuning on AlexNet CNN with batch size 12, dropout 0.2, Adam optimizer produces the best results in terms of accuracy values of 84%, precision of 81.95%, recall of 80.66%, and f1-score of 80.96%.

Keywords: AlexNet, Classification, Convolutional Neural Network, Hyperparameters, Soybean.

I. PENDAHULUAN

Mengingat pangan merupakan kebutuhan dasar manusia dan seluruh rakyat Indonesia berhak untuk terpenuhi kebutuhannya, tanaman pangan merupakan komoditas strategis dan penting. Salah satu bahan pangan yang sangat vital bagi gizi manusia adalah kedelai. [1]. Menurut (Glycine Max), kedelai merupakan bahan pangan yang populer karena selain sebagai sumber protein nabati yang paling sehat, juga merupakan bahan pangan yang murah dan terjangkau bagi sebagian besar masyarakat Indonesia [2]. Kedelai diolah menjadi berbagai produk makanan seperti tempe, tahu, tauco, kecap, susu, dan lain-lain, dengan permintaan yang terus meningkat dari tahun ke tahun sebanding dengan pertambahan jumlah penduduk [2]. Menanggapi meningkatnya permintaan produk pertanian dalam negeri dan pembatasan produksi dalam negeri, pemerintah meningkatkan impor pertanian [1]. Indonesia saat ini merupakan salah satu importir kedelai terbesar di dunia. Setiap tahun rata-rata volume ekspor kedelai melebihi satu juta ton dari total rata-rata permintaan di atas dua juta ton [3]. Sekitar 88% dari jumlah tersebut digunakan sebagai bahan baku pembuatan tempe dan tahu, 10% untuk makanan olahan lainnya seperti industri tepung dan pati, dan 2% sisanya untuk biji-bijian. Kedelai paling sering diimpor dari Amerika Serikat, Kanada, Argentina, dan Brasil [2]. Hasil panen kedelai Indonesia sekitar 1,2 ton/ha, masih jauh di bawah potensi hasil 2-2,5 ton/ha [4]. Gangguan penyakit pada tanaman kedelai merupakan salah satu penyebab rendahnya hasil [5]. Di Indonesia terdapat lebih dari 20 jenis penyakit tanaman yang disebabkan oleh cendawan, bakteri, virus, dan mikoplasma. Akibatnya, petani harus mengetahui penyakit yang menyerang kedelai untuk memilih jenis penyakit dan tindakan pengobatan yang tepat [4].

Secara umum, pemeriksaan laboratorium, pemeriksaan visual, dan penilaian gejala merupakan metode yang efektif untuk mendiagnosis penyakit kedelai [6]. Dengan adanya penggunaan bahan kimia dan proses yang panjang, diagnosis penyakit di laboratorium masih belum efektif [7]. Persepsi orang terhadap hal-hal visual berbeda-beda, sehingga identifikasi visual merupakan proses subjektif yang masih dianggap rawan kesalahan [8]. Kedua cara tradisional ini bergantung pada keterlibatan seorang ahli untuk dapat mengenali penyakitnya [6].

Computer vision dan pembelajaran mendalam dapat digunakan untuk mengenali objek menggunakan kemajuan teknologi saat ini, seperti yang terlihat dalam pendekripsi Covid-19 [9], klasifikasi citra lesi kulit serupa virus *monkeypox* [6] dan identifikasi jenis tumbuhan [10]. Metode *Convolutional Neural Network* adalah teknik pembelajaran mendalam yang paling sering digunakan saat ini [11]. Saat objek dimasuki, CNN memiliki kemampuan dasar untuk mengenali informasi prediktif tentang hal-hal tersebut, termasuk foto, teks, audio, dan video, terlepas dari lokasi objek tersebut [8].

Arsitektur LeNet CNN digunakan pada penelitian sebelumnya [12] pada pendekripsi penyakit tanaman kedelai, dengan total dataset sebanyak 12.673 citra yang terbagi dalam 4 kelas. Hasil dari penelitian tersebut menghasilkan nilai akurasi yakni, sebesar 99,21%. Penelitian selanjutnya juga pernah dilakukan [13] mengenai klasifikasi penyakit daun kedelai menggunakan 3 arsitektur canggih berbasis buatan tangan ditambah 6 arsitektur CNN yang populer yakni, VGG19, GoogleNet, Dense121, XceptionNet, LeNet dan ResNet50, dari 9 arsitektur gabungan tersebut diberi nama “SoyNet”. Jumlah dataset yang digunakan sebanyak 17.240 citra berupa citra augmentasi yang terdiri dari 16 kelas. Hasil penelitian tersebut menghasilkan nilai akurasi 98,14%, *precision* 97%, *recall* 97%, serta F1-Score 97%.

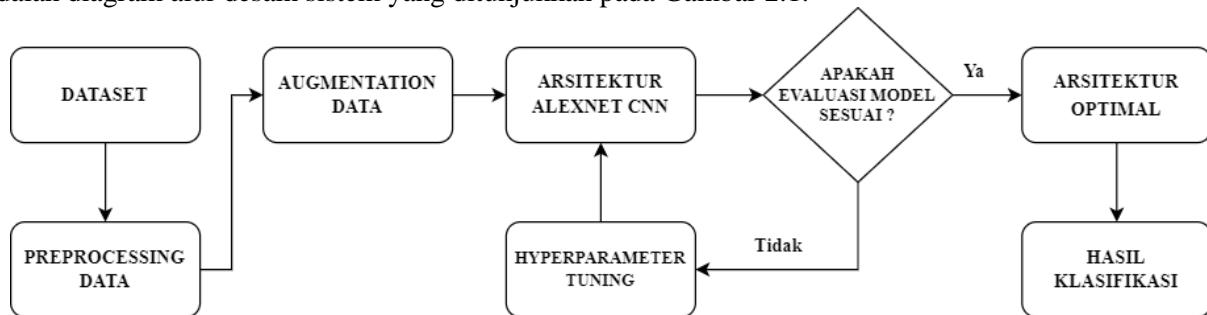
Pada tahun 2012, kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC), tantangan klasifikasi gambar berskala besar, dimenangkan oleh arsitek AlexNet CNN [14]. Dengan memanfaatkan ConvNet bersama dengan pendekatan regularisasi *dropout*, menggunakan ReLu sebagai fungsi aktivasi, dan augmentasi data, AlexNet telah muncul sebagai pengembangan baru dalam pembelajaran mendalam. AlexNet dibuat untuk dapat mengkategorikan dengan 1.000 kategori berbeda [15]. Struktur AlexNet terdiri dari terdiri dari 5 *convolution layer*, 3 *pooling layer*, 2 *dropout layer*, dan 3 *fully connected layer* [16]. Penelitian terdahulu yang menggunakan AlexNet pernah dilakukan [16] dengan mengklasifikasikan hama daun tanaman kopi berbasis citra dengan jumlah dataset sebanyak 300 citra, menghasilkan akurasi sebesar 81,6%. Serta identifikasi jenis tumbuhan berdasarkan citra daun dilakukan [17] dengan jumlah dataset sebanyak 2.000 citra, menghasilkan akurasi sebesar 90%. Arsitektur CNN bekerja cukup baik, tetapi dengan menyempurnakan *hyperparameter*, kinerja ini dapat lebih ditingkatkan untuk menghasilkan arsitektur yang lebih optimal. Untuk mengoptimalkan dan

meningkatkan performa arsitektur CNN dilakukan dengan penyesuaian *hyperparameter*. Nilai *epoch*, ukuran *batch size*, *optimizer*, *learning rate*, dan *hyperparameter* lainnya mungkin perlu disetel [8].

Berdasarkan deskripsi latar belakang, pada penelitian [12] dan [13] belum pernah dilakukan penelitian menggunakan arsitektur AlexNet CNN. Pada penelitian ini, arsitektur AlexNet CNN akan dilakukan pengujian dengan *hyperparameter* yang telah ditentukan dengan mengukur nilai akurasi, presisi, *recall* dan *f1-score*. Pengujian *hyperparameter* yang dilakukan bertujuan untuk mengoptimalkan arsitektur yang telah dirancang sebelumnya. Sehingga, penelitian ini mengusulkan pemilihan *hyperparameter* pada arsitektur AlexNet CNN untuk klasifikasi citra penyakit kedelai [18].

II. METODE PENELITIAN

Metode penelitian ini merupakan tahapan dari penerapan arsitektur AlexNet CNN yang dilakukan pada dataset citra penyakit tanaman kedelai dengan tujuan untuk klasifikasi penyakit pada tanaman kedelai. Dataset yang digunakan bersifat *public dataset* yang didapat dari website Kaggle. Berikut adalah diagram alur desain sistem yang ditunjukkan pada Gambar 2.1.



Gambar 2.1 Diagram Alur Desain Sistem

A. Dataset

Citra penyakit tanaman kedelai yang diambil dari website Kaggle digunakan sebagai dataset untuk penelitian ini. Dataset yang digunakan berjumlah 1.500 citra yang terdiri dari 3 kelas yakni *Caterpillar* berjumlah 500 citra, *Diabrotica Speciosa* berjumlah 500 citra, dan *Healthy* berjumlah 500 citra. Dataset penelitian dapat diakses pada situs <https://www.kaggle.com/shuvoalok98/soybean-disease-dataset>.

B. Pre-Processing Data dan Augmentasi Data

Pada proses *pre-processing* data akan dilakukan pembagian data dan *resize* citra. Pembagian dataset dilakukan dengan perbandingan 8:1:1. Perbandingan 8 untuk data latih, 1 untuk data uji, dan 1 untuk data validasi. Selanjutnya, dilakukan proses *resize* citra untuk menetapkan seluruh ukuran resolusi citra menjadi 227x227 piksel.

Augmentasi data yang dilakukan pada penelitian ini bersifat *on the fly*. Beberapa teknik augmentasi data yang dilakukan seperti *pad & crop*, *rotate*, *horizontal flip*, *zoom* dan *vertical flip*.

C. Arsitektur AlexNet CNN

Arsitektur AlexNet CNN adalah model yang digunakan dalam penelitian ini, yang terdiri dari 5 *convolutional layer*, 3 *pooling layer*, 2 *dropout layer*, dan 3 *fully connected layer*. Berikut merupakan penjelasan secara detail dari arsitektur AlexNet CNN yang ditunjukkan pada Tabel 2.1.

Tabel 2.1 Arsitektur Alexnet CNN

Layer	Filter	Size	Kernel Size	Stride	Activation
<i>Input</i>	1	227x227x3	-	-	-
<i>Convolution 1</i>	96	55x55x96	11x11	4	ReLu
<i>Pooling 1</i>	96	27x27x96	3x3	2	ReLu
<i>Convolution 2</i>	256	27x27x256	5x5	1	ReLu
<i>Pooling 2</i>	256	13x13x256	3x3	2	ReLu

<i>Convolution 3</i>	384	13x13x384	3x3	1	ReLU
<i>Convolution 4</i>	384	13x13x384	3x3	1	ReLU
<i>Convolution 5</i>	256	13x13x256	3x3	1	ReLU
<i>Pooling 3</i>	256	6x6x256	3x3	2	ReLU
<i>Fully Connected 1</i>	-	9216	-	-	ReLU
<i>Fully Connected 2</i>	-	4096	-	-	ReLU
<i>Fully Connected 3</i>	-	4096	-	-	ReLU
<i>Output</i>	-	1000	-	-	Softmax

D. Hyperparameter Tuning

Performa algoritma pembelajaran mesin dapat ditingkatkan secara signifikan melalui penyesuaian *hyperparameter* [19]. Nilai *hyperparameter* tidak dapat ditentukan dari data dan kami selalu menganggapnya sebagai nilai yang diberikan saat mendefinisikan model, dengan kata lain, nilai *hyperparameter* harus ditentukan sebelum model dapat ditentukan proses pembelajarannya [20]. *Hyperparameter* adalah variabel yang mempengaruhi *output* dari sebuah model [21]. Pada penelitian ini, *Hyperparameter Tuning* yang dipilih untuk memberikan parameter terbaik melalui perbandingan yang diusulkan. *Hyperparameter Tuning* diilustrasikan pada Tabel 2.2, sebagai berikut.

Tabel 2.2 Hyperparameter Tuning

Parameter	Nilai Perbandingan
Dropout	0.2, 0.5
Batch Size	16, 32, 64
Optimizer	Adam, Adamax, RMSProp, SGD

E. Evaluasi Model

Pada penelitian ini, evaluasi model dari AlexNet CNN menggunakan *confusion matrix*. Pengertian *confusion matrix* adalah teknik untuk menilai efektivitas dari hasil proses klasifikasi [22]. Pada penilaian menggunakan *confusion matrix* terdapat beberapa istilah parameter pengukuran yang digunakan, diantaranya *True Positive* (TP) adalah proses mengidentifikasi data positif dengan benar [23], *False Positive* (FP) adalah proses mengidentifikasi data positif dengan salah [24], *False Negative* (FN) adalah proses mengidentifikasi data negatif dengan salah [25], dan *True Negative* (TN) adalah proses mengidentifikasi data negatif dengan benar [6]. Berikut adalah persamaan matematika dari *confusion matrix*.

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

$$\text{Presisi} = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

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

$$F1 - Score = 2 \times \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \times 100\% \quad (4)$$

III. HASIL DAN PEMBAHASAN

Hasil pengujian yang telah dilakukan akan dijelaskan pada bab ini. Penelitian ini memiliki 3 skenario pengujian dengan parameter yang berbeda, dan bertujuan untuk mengetahui seberapa besar pengaruh *hyperparameter tuning* pada model AlexNet CNN yang telah dikembangkan. Berikut penjelasan dari beberapa skenario yang ditunjukkan pada Tabel 3.1.

Tabel 3.1 Penjelasan berdasarkan Beberapa Skenario

Skenario	Penjelasan
Skenario 1	Menggunakan parameter dari hasil <i>hyperparameter tuning</i> terbaik ke-1
Skenario 2	Menggunakan parameter dari hasil <i>hyperparameter tuning</i> terbaik ke-2
Skenario 3	Menggunakan parameter dari hasil <i>hyperparameter tuning</i> terbaik ke-3

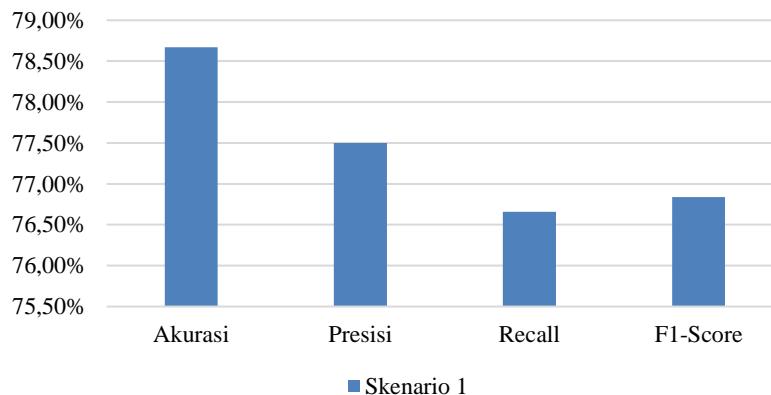
Hyperparameter tuning yang tertera pada Tabel 3.1, akan dilakukan pelatihan terlebih dahulu dari beberapa parameter yang telah ditetapkan, dengan tujuan untuk mendapatkan *hyperparameter tuning* yang terbaik. Setelah mendapatkan *hyperparameter tuning* yang terbaik, selanjutnya akan dilakukan pengambilan *hyperparameter tuning* terbaik sebanyak 3 sampel yang nantinya akan dilakukan pengujian dan evaluasi. Pengujian yang akan dilakukan terbagi 3 skenario, masing-masing skenario menggunakan parameter yang termuat pada Tabel 3.2.

Tabel 3.2 Hasil Hyperparameter Tuning Terbaik

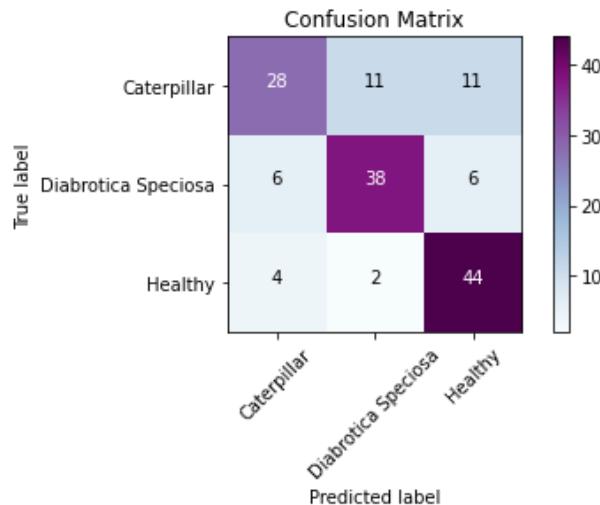
Skenario	Batch Size	Dropout	Optimizer
1	64	0.5	Adamax
2	16	0.2	Adam
3	32	0.5	Adamax

A. Pengujian Skenario 1

Pada pengujian skenario 1, arsitektur AlexNet CNN akan dilakukan pelatihan dengan menggunakan parameter terbaik dari hasil *hyperparameter tuning* sebelumnya. Parameter yang digunakan yakni *batch_size* = 64, *dropout* = 0.5, dan *optimizer* = Adamax. Hasil pengujian skenario 1 termuat pada Gambar 3.1.

**Gambar 3.1** Hasil Pengujian Skenario 1

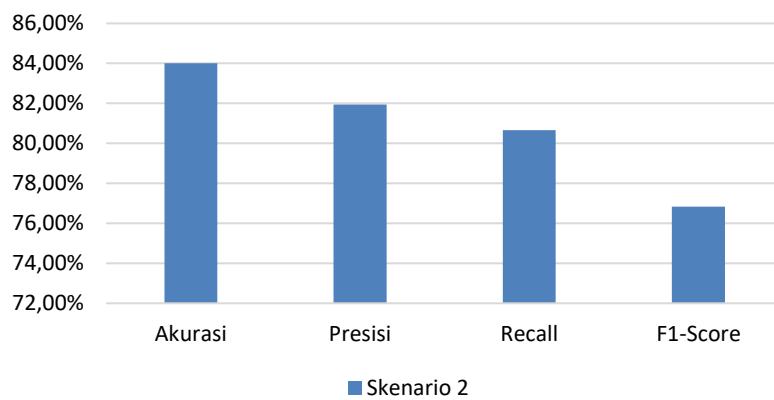
Pada skenario 1, proses pelatihan model menghasilkan akurasi 78,67% dalam waktu 34 menit. Kemudian, model skenario 1 dilakukan evaluasi menggunakan *confusion matrix* dengan persamaan matematika (1), (2), (3), dan (4). Sehingga, didapatkan nilai *recall* 76,66%, presisi 77,50%, dan *f1-score* 76,84%. Berikut adalah visualisasi dari *confusion matrix* yang ditunjukkan pada Gambar 3.2.

**Gambar 3.2** *Confusion Matrix Skenario 1*

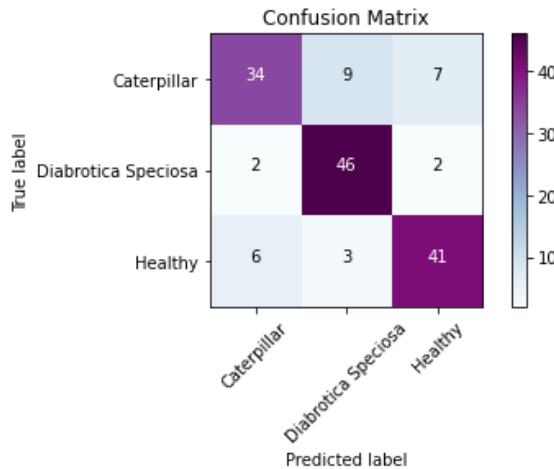
Gambar 3.2 menampilkan evaluasi model dari pengujian menggunakan skenario 1. Data yang diprediksi benar ditandai dengan warna biru, ungu, dan biru tua yang berjumlah 110 citra. Sedangkan, data yang diprediksi salah ditandai dengan warna biru muda, dan biru agak keputihan yang berjumlah 40 citra.

B. Pengujian Skenario 2

Pada pengujian skenario 2, arsitektur AlexNet CNN akan dilakukan pelatihan menggunakan parameter yang berbeda dari parameter skenario 1. Parameter yang digunakan sudah tertera pada Tabel 4., diantaranya *batch_size* = 16, *dropout* = 0.2, dan *optimizer* = Adam. Berikut adalah Chart 2., hasil pengujian dari skenario 2.

**Gambar 3.3** Hasil Pengujian Skenario 2

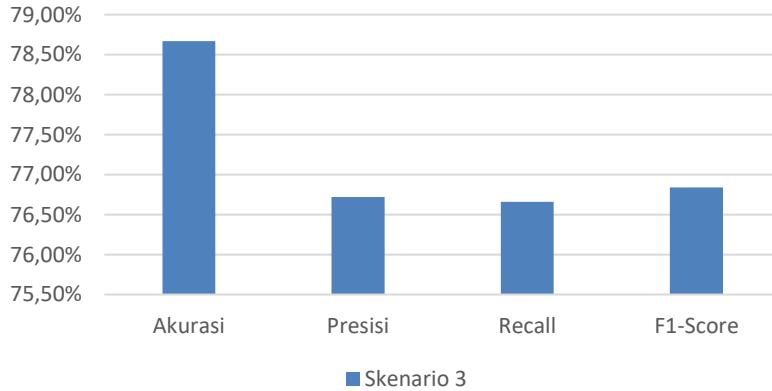
Pada skenario 2, proses pelatihan model menghasilkan nilai akurasi 84,00% dalam waktu 31 menit. Kemudian, model skenario 2 dilakukan evaluasi menggunakan *confusion matrix* dengan persamaan matematika (1), (2), (3), dan (4).. Sehingga, didapatkan nilai *fi-score* 80,96%, presisi 81,95%, dan *recall* 80,66%. Berikut adalah visualisasi dari *confusion matrix* yang ditunjukkan pada Gambar 3.4.

**Gambar 3.4** Confusion Matrix Skenario 2

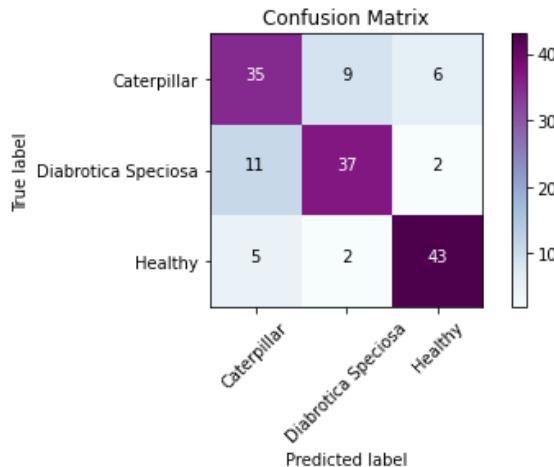
Gambar 3.4 menampilkan evaluasi model dari pengujian skenario 2. Data yang diprediksi benar ditandai dengan warna biru, ungu, dan biru tua yang berjumlah 121 citra. Sedangkan, data yang diprediksi salah ditandai dengan warna biru muda, dan biru agak keputihan yang berjumlah 29 citra.

C. Pengujian Skenario 3

Pada pengujian skenario 3, arsitektur AlexNet CNN akan dilakukan pelatihan menggunakan parameter yang berbeda dari parameter skenario 1 dan skenario 2. Parameter yang digunakan sudah tertera pada Tabel 4., diantaranya *batch_size* = 16, *dropout* = 0.2, dan *optimizer* = Adam. Hasil pengujian skenario 1 termuat pada Gambar 3.5.

**Gambar 3.5** Hasil Pengujian Skenario 3

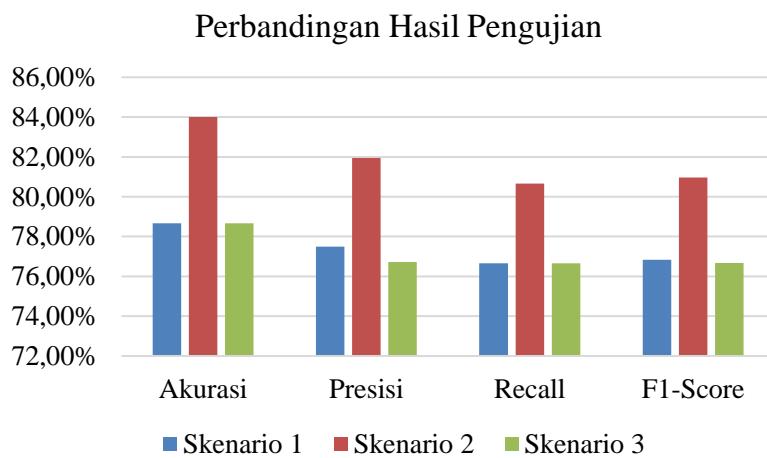
Pada skenario 3, proses pelatihan model menghasilkan nilai akurasi 78,67% dalam waktu 33 menit. Kemudian, model skenario 3 dilakukan evaluasi menggunakan confusion matrix dengan persamaan matematika (1), (2), (3), dan (4). Sehingga, didapatkan nilai presisi 76,72%, *recall* 76,66%, dan *f1-score* 76,67%. Berikut adalah visualisasi dari *confusion matrix* yang ditunjukkan pada Gambar 3.6.

**Gambar 3.6 Confusion Matrix Skenario 3**

Gambar 3.6 menampilkan evaluasi model dari pengujian skenario 3. Data yang diprediksi benar ditandai dengan warna biru, ungu, dan biru tua yang berjumlah 115 citra. Sedangkan, data yang diprediksi salah ditandai dengan warna biru muda, dan biru agak keputihan yang berjumlah 35 citra.

D. Evaluasi Pengujian Skenario

Hasil pengujian untuk setiap skenario menunjukkan bahwa ada perubahan yang cukup signifikan dari penerapan *hyperparameter tuning*, dalam menentukan parameter terbaik untuk arsitektur AlexNet CNN. Hasil pengujian tersebut berupa akurasi, *recall*, *f1-score*, dan presisi yang ditunjukkan pada Gambar 4.1



IV. KESIMPULAN

Berdasarkan hasil pengamatan selama perancangan, pengujian, dan implementasi bahwasanya penelitian ini melakukan penerapan *hyperparameter tuning* pada arsitektur AlexNet CNN untuk klasifikasi citra penyakit kedelai. Tujuan dari penelitian ini adalah untuk mendapatkan *hyperparameter* optimal yang bekerja dengan baik pada model AlexNet CNN. Evaluasi model pada penelitian ini menggunakan *confusion matrix* dengan menghitung nilai akurasi, presisi, *recall*, dan *f1-score*. Pada penelitian ini melakukan 3 kali skenario pengujian dengan tujuan untuk membandingkan hasil terbaik *hyperparameter tuning* dari 3 skenario, sehingga didapatkan hasil terbaik pada skenario 2 dengan nilai akurasi 84,00%, presisi 81,95%, *recall* 80,66%, serta *f1-score* 80,96%.

DAFTAR PUSTAKA

- [1] T. Sundari and A. Taufiq, “Respons Tanaman Kedelai Terhadap Lingkungan Tumbuh,” *Bul. Palawija*, vol. 26, no. 23, pp. 13–26, 2012.
- [2] N. Saleh, “Strategi Pengendalian Penyakit Tanaman Kedelai,” *Bul. Palawija*, vol. 0, no. 7–8, pp. 51–60, 2004.
- [3] Nur Lalily Abidah, “Klasifikasi Hama dan Penyakit Pada Tanaman Jagung Menggunakan Metode Random Forest Berdasarkan Repeated K-Fold Cross Validation,” 2022.
- [4] Badan Pusat Statistik, “Impor Kedelai Menurut Negara Asal Utama, 2017-2021,” p. 2021, 2022.
- [5] Z. Zhang, S. Khanal, A. Raudenbush, K. Tilmon, and C. Stewart, “Assessing the efficacy of machine learning techniques to characterize soybean defoliation from unmanned aerial vehicles,” *Comput. Electron. Agric.*, vol. 193, 2022, doi: 10.1016/j.compag.2021.106682.
- [6] L. A. Susanto, A. Nilogiri, and L. Handayani, “Klasifikasi Citra Lesi Kulit Serupa Virus Monkeypox Menggunakan VGG-19 Convolutional Neural Network,” *J. Sist. dan Teknol. Inf.*, vol. 8, no. 1, pp. 1–9, 2023, doi: <https://doi.org/10.32528/justindo.v8i1.168> Klasifikasi.
- [7] W. Setiawan, “Perbandingan Arsitektur Convolutional Neural Network Untuk Klasifikasi Fundus,” *J. Simantec*, vol. 7, no. 2, pp. 48–53, 2020, doi: 10.21107/simantec.v7i2.6551.
- [8] A. Julianto, A. Sunyoto, D. Ferry, and W. Wibowo, “Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi (Optimization of Convolutional Neural Network Hyperparameters for Classification of Rice Plant Diseases),” *TEKNIMEDIA*, vol. 3, no. 2, pp. 98–105, 2022.
- [9] J. Xiao, J. Wang, S. Cao, and B. Li, “Application of a Novel and Improved VGG-19 Network in the Detection of Workers Wearing Masks,” *J. Phys. Conf. Ser.*, vol. 1518, no. 1, 2020, doi: 10.1088/1742-6596/1518/1/012041.
- [10] R. Setyawan, “Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan 19 Layers Deep Convolutional Neural Network (Vgg-19),” no. 8.5.2017, pp. 2003–2005, 2022.
- [11] V. S. Babu and N. V. Ram, “Deep Residual CNN with Contrast Limited Adaptive Histogram Equalization for Weed Detection in Soybean Crops,” *Trait. du Signal*, vol. 39, no. 2, pp. 717–722, 2022, doi: 10.18280/ts.390236.
- [12] S. Walleigh, M. Polceanu, and C. Buche, “Soybean plant disease identification using convolutional neural network,” *Proc. 31st Int. Florida Artif. Intell. Res. Soc. Conf. FLAIRS 2018*, pp. 146–151, 2018.
- [13] A. Karlekar and A. Seal, “SoyNet: Soybean leaf diseases classification,” *Comput. Electron. Agric.*, vol. 172, no. November 2019, 2020, doi: 10.1016/j.compag.2020.105342.
- [14] D. K. Agarwal, S. D. Billore, A. N. Sharma, B. U. Dupare, and S. K. Srivastava, “Soybean: Introduction, Improvement, and Utilization in India-Problems and Prospects,” *Agric. Res.*, vol. 2, no. 4, pp. 293–300, 2013, doi: 10.1007/s40003-013-0088-0.
- [15] A. Krizhevsky, I. Sustkever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Handb. Approx. Algorithms Metaheuristics*, pp. 1–1432, 2007, doi: 10.1201/9781420010749.
- [16] D. Irfansyah, M. Mustikasari, and A. Suroso, “Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi,” *J. Inform. J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021.
- [17] S. Ilahiyah and A. Nilogiri, “Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network,” *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.
- [18] Y. Li *et al.*, “Soybean seed counting based on pod image using two-column convolution neural network,” *IEEE Access*, vol. 7, pp. 64177–64185, 2019, doi: 10.1109/ACCESS.2019.2916931.
- [19] W. Nugraha and A. Sasongko, “Hyperparameter Tuning pada Algoritma Klasifikasi dengan Grid Search,” *Sist. J. Sist. Inf.*, vol. 11, no. 2, pp. 391–401, 2022.
- [20] X. Zhang, X. Chen, L. Yao, C. Ge, and M. Dong, “Deep neural network hyperparameter optimization with orthogonal array tuning,” *Commun. Comput. Inf. Sci.*, vol. 1142 CCIS, pp. 287–295, 2019, doi: 10.1007/978-3-030-36808-1_31.

- [21] S. Lasniari, S. Sanjaya, F. Yanto, and M. Affandes, “Pengaruh Hyperparameter Convolutional Neural Network Arsitektur ResNet-50 Pada Klasifikasi Citra Daging Sapi dan Daging Babi,” vol. 5, no. 3, pp. 474–481, 2022.
- [22] Karsito and S. Susanti, “Klasifikasi Kelayakan Peserta Pengajuan Kredit Rumah Dengan Algoritma Naïve Bayes Di Perumahan Azzura Residencia,” *J. Teknol. Pelita Bangsa*, vol. 9, pp. 43–48, 2019.
- [23] L. A. da Silva, P. O. Bressan, D. N. Gonçalves, D. M. Freitas, B. B. Machado, and W. N. Gonçalves, “Estimating soybean leaf defoliation using convolutional neural networks and synthetic images,” *Comput. Electron. Agric.*, vol. 156, no. September 2018, pp. 360–368, 2019, doi: 10.1016/j.compag.2018.11.040.
- [24] X. Zhang *et al.*, “Weed Identification in Soybean Seedling Stage Based on Optimized Faster R-CNN Algorithm,” *Agric.*, vol. 13, no. 1, pp. 1–16, 2023, doi: 10.3390/agriculture13010175.
- [25] R. Kamal, S. Tiwari, S. Kolhe, and M. V. Deshpande, “A Design Approach for Identifying, Diagnosing and Controlling Soybean Diseases using CNN Based Computer Vision of the Leaves for Optimizing the Production,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1099, no. 1, p. 012037, 2021, doi: 10.1088/1757-899x/1099/1/012037.