

Contents list available at www.jurnal.unimed.ac.id

CESS
(Journal of Computing Engineering, System and Science)

journal homepage: <https://jurnal.unimed.ac.id/2012/index.php/cess>



**Optimalisasi Epoch Pada Klasifikasi Citra Daun Tanaman Padi
Menggunakan Convolutional Neural Network (CNN) MobileNet**

**Epoch Optimization on Rice Leaf Image Classification Using Convolutional
Neural Network (CNN) MobileNet**

Fauzan Masykur^{1*}, Mohammad Bhanu Setyawan², Kuntang Winangun³

^{1,2} Fakultas Teknik, Teknik Informatika, Universitas Muhammadiyah Ponorogo
Jalan Budi Utomo No.10 Ponorogo

³ Fakultas Teknik, Teknik Mesin, Universitas Muhammadiyah Ponorogo
Jalan Budi Utomo No.10 Ponorogo

email: 1fauzan@umpo.ac.id, 2m.banu@umpo.ac.id, 3kuntang@gmail.com

Submitted: 29 Juli 2022 | Review: 03 Agustus 2022 | Accepted: 13 Agustus 2022

ABSTRAK

Epoch pada proses klasifikasi citra menggunakan algoritma deep learning convolutional neural network (CNN) merupakan proses yang mutlak dibutuhkan untuk mencapai akurasi paling optimal dan loss yang kecil. Penentuan epoch akan mempengaruhi bobot (weight) pada neural network serta berpengaruh pada kurva yang dihasilkan. Proses training dataset citra pada neural network akan melalui satu rangkaian perhitungan dari awal sampai akhir hingga akan dikembalikan lagi ke proses awal dengan sebutan sekali putaran atau 1 epoch. Proses pembelajaran dari dataset diperlukan beberapa kali update bobot sehingga akan kurang optimal jika epoch dilakukan hanya sekali putaran. Pada makalah ini akan dipaparkan klasifikasi citra daun tanaman padi yang menggunakan arsitektur CNN MobileNet dengan beberapa kali epoch untuk menghasilkan hasil yang paling optimal. Citra daun dibagi menjadi 4 kelas yakni healthy, brownspot, hispa dan leafblast. Setiap kelas di kelompokkan menjadi 2 kelompok yaitu data training dan data validasi dengan presentase data training 70% dan data testing 30%. Sedangkan epoch yang ditentukan sebanyak 50, 100 dan 150 kali. Pada epoch 150 menghasilkan nilai akurasi tertinggi senilai 1,000 dan loss senilai 0,0037 yang artinya semakin besar nilai epoch akan menghasilkan akurasi terbaik pada klasifikasi citra daun padi menggunakan MobileNet.

Kata Kunci: *Epoch; Deep Learning; Convolutional Neural Network; Mobilenet*

ABSTRACT

Epoch in the image classification process using the deep learning convolutional neural network (CNN) algorithm is a process that is absolutely needed to achieve the most optimal accuracy and small loss. Determining the epoch will affect the weight (weight) in the neural network as well as affect the resulting curve. The image dataset training process on the neural network will go through a series of calculations from start to finish until it will be returned to the initial process as one round or 1 epoch. The learning process from the dataset requires several times to update the weights so that it will be less than optimal if the epoch is done only one round. This paper will describe the classification of rice leaf imagery using the CNN MobileNet architecture with several periods to produce the most optimal results. Leaf images are divided into 4 classes, namely healthy, brownspot, hispa and leafblast. Each class is grouped into 2 groups, namely training data and data validation with a percentage of 70% training data and 30% testing data. While the specified epochs are 50, 100 and 150 times. At epoch 150 the highest accuracy value is 1,000 and loss is 0.0037, which means that the greater the epoch value will produce the best accuracy in rice leaf image classification using MobileNet.

Keywords: *Epoch; Deep Learning; Convolutional Neural Network; Mobilenet*

1. PENDAHULUAN

Berdasarkan data FAO (Food and Agriculture Organization) Indonesia merupakan negara dengan penghasil beras ketiga di dunia dengan produksi 54,65 juta ton pada tahun 2020. Namun disisi lain Indonesia juga merupakan negara dengan konsumsi beras terbesar di dunia, artinya Indonesia sangat tergantung pada kebutuhan pokok berupa beras sebagai makanan pokok 270 juta penduduk Indonesia. Mengacu data resmi pada Badan Pusat Statistik (BPS) tahun 2020 bahwa produksi beras pada tahun 2020 meningkat sebesar 0,05 juta ton atau naik sebesar 0,08% dari tahun sebelumnya.

Tingginya hasil panen padi tidak luput dari serangan hama dan penyakit yang bisa berakibat menurunnya hasil panen. Hama biasanya disebabkan oleh hewan pengganggu yang menyerang tanaman pada saat tanaman memasuki fase generatif maupun vegetatif. Sedangkan penyakit tanaman padi disebabkan oleh serangan virus atau bakteri pada bagian daun maupun pada batang tanaman padi. Hama dan penyakit tanaman padi yang tidak terkendali akan menyebabkan gagal panen sehingga berujung pada terganggunya produksi beras. Saat ini yang sering dilakukan petani dalam mengatasi serangan hama dan penyakit tanaman padi yaitu dengan cara penggunaan pestisida kimia [1].

Penggunaan pestisida kimia dalam mengatasi serangan hama dan penyakit bisa dikurangi dengan deteksi dini serangan dengan penggunaan teknologi *Artificial Intelligent* (AI). Keterlambatan dalam deteksi akan berakibat gagal panen dan kerugian akan dialami petani. Algoritma AI saat ini yang berkembang untuk mendeteksi keberadaan hama dan penyakit tanaman yakni dengan memanfaatkan citra digital sebagai data inputan. selain itu, AI juga bisa dikolaborasikan dengan Internet of Things untuk mengatasi permasalahan dibidang pertanian[2][3].

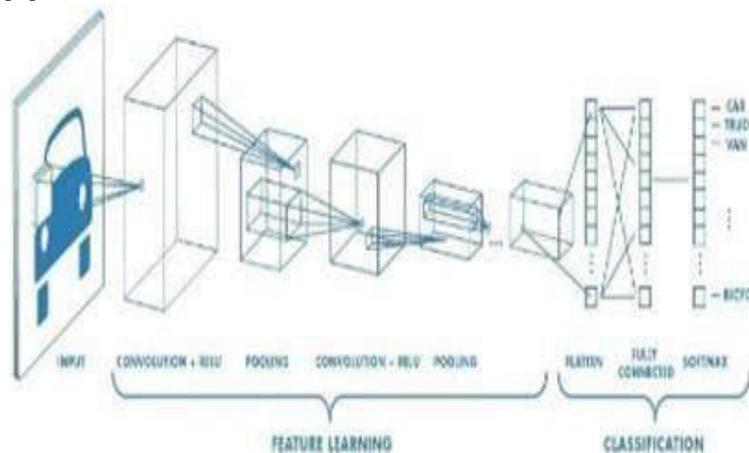
Algoritma deep learning pada pengolahan citra digital yang dikenal saat ini salah satunya Convolutional Neural Network (CNN) dengan berbagai macam arsitektur dan cara kerjanya [4]. Salah satu penerapan CNN yakni pada klasifikasi penyakit pada daun tanaman padi yang sering menyerang tanaman padi dengan akibat gagal panen. Citra daun tanaman padi sehat

maupun berpenyakit akan menjadi inputan atau sebagai dataset dalam penentuan penyakit tanaman padi.

Penelitian dengan konsep CNN telah banyak digunakan pada bidang pertanian seperti klasifikasi penyakit pada daun jagung dengan dataset citra sebanyak 200 citra yang terdiri dari 4 kelas yakni healthy, cercospora, common rust dan leaf blight. Penelitian tersebut menggunakan 7 model CNN dan KNN (K-Nearest Neighbour) sebagai metode klasifikasinya. Hasil dari penelitian menunjukkan model Alexnet dan klasifikasi metode Support Vector Machine memiliki nilai yang paling baik yakni akurasi senilai 93,5%, sensitivitas senilai 95,08% dan spesififikasi senilai 93% [5].

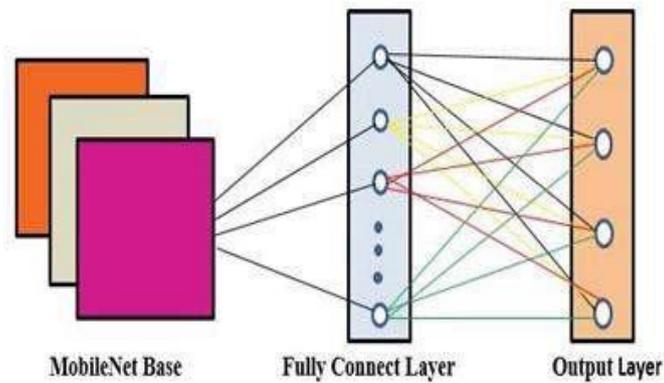
Klasifikasi citra daun dengan algoritma deep learning tidak lepas dari penerapan epoch, iterasi dan batch size. Penerapan epoch merupakan proses satu putaran training seluruh dataset dalam neural network sampai kembali ke awal proses. Kondisi yang juga diperlukan dalam penentuan epoch adalah kasus underfitting maupun overfitting [6] [7]. Pada makalah ini akan menyajikan seberapa pengaruh epoch pada klasifikasi citra daun tanaman padi dengan 4 kelas yakni healthy, brownspot, leafblast dan hispa.

Seperti pada jaringan syaraf tiruan yang lainnya dengan memiliki bobot, bias, fungsi aktivasi dan penggunaan layer pada CNN memiliki perbedaan yang tidak dimiliki jaringan syaraf lainnya yakni terletak pada bagian layer konvolusi. Layer konvolusi merupakan pengolahan citra digital dengan memanfaatkan fitur kernel dengan memecah citra menjadi beberapa langkah untuk mendapatkan ekstraksi ciri sebuah citra. Pada gambar 1 ditunjukkan proses kerja CNN [8].



Gambar 1. Cara Kerja Convolutional Neural Network

Arsitektur CNN yang sering digunakan antara lain AlexNet, GoogLeNet [9], Resnet, VGGnet dan arsitektur untuk penggunaan mobile berupa arsitektur MobileNet. Pada penelitian pengaruh epoch ini menggunakan arsitektur MobileNet dikarenakan proses komputasi yang cepat dan resources yang dibutuhkan lebih rendah [10].

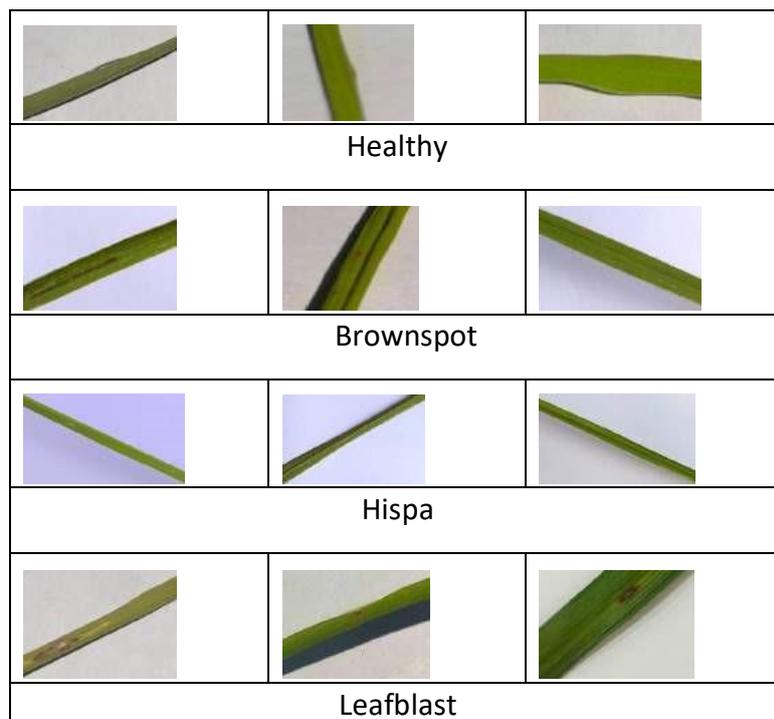


Gambar 2. Model MobileNet

Epoch pada proses klasifikasi menggunakan CNN merupakan bagian tak terpisahkan dalam mencari hasil klasifikasi yang tepat. Pada penelitian kali ini akan mencari hasil terbaik dalam klasifikasi citra daun tanaman padi dengan 4 kelas menggunakan arsitektur MobileNet. Epoch yang digunakan sebanyak 3 nilai yakni 50, 100 dan 150.

2. METODE

Dataset citra daun padi diperoleh dari data publik www.kaggle.com yang meliputi 4 kelas yakni *healthy*, *brownspot*, *hispa* dan *leaf blast*. Tabel 1. menunjukkan ringkasan jumlah dataset dari tiap-tiap kelas. Perhitungan pengaruh epoch pada klasifikasi citra menggunakan google colab dengan mengkombinasikan Epoch sebanyak 3 nilai yakni 50, 100 dan 150.



Gambar 3. Dataset citra daun padi 4 kelas

Arsitektur yang digunakan pada klasifikasi citra daun padi menggunakan arsitektur MobileNet yang memiliki keunggulan *resources* yang dibutuhkan lebih sedikit. Pada tabel 1 ditunjukkan potongan model MobileNet.

Tabel 1. Model Arsitektur MobileNet

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
conv1 (Conv2D)	(None, 112, 112, 32)	864
conv1_bn (BatchNormalization)	(None, 112, 112, 32)	128
conv1_relu (ReLU)	(None, 112, 112, 32)	0
conv_dw_1 (DepthwiseConv2D)	(None, 112, 112, 32)	288
conv_dw_1_bn (BatchNormalization)	(None, 112, 112, 32)	128
conv_dw_1_relu (ReLU)	(None, 112, 112, 32)	0
conv_pw_1 (Conv2D)	(None, 112, 112, 64)	2048
conv_pw_1_bn (BatchNormalization)	(None, 112, 112, 64)	256

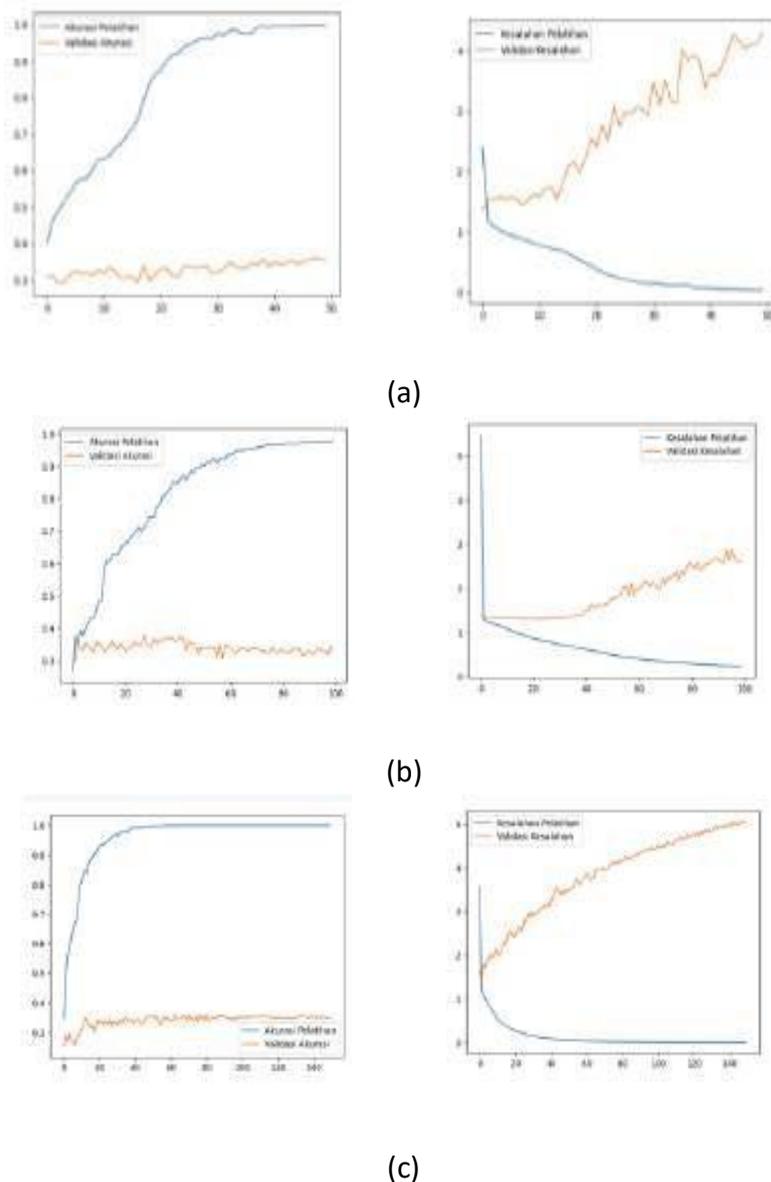
Dataset dibagi menjadi 4 kelas dengan masing-masing melalui proses pre-processing dan anotasi data untuk menyamakan file ekstensi menyesuaikan konsep deep learning khususnya CNN. Pada Gambar 3 merupakan tampilan citra dataset 4 kelas. Arsitektur yang digunakan pada klasifikasi citra daun padi menggunakan arsitektur MobileNet yang memiliki keunggulan *resources* yang dibutuhkan lebih sedikit.

3. HASIL DAN PEMBAHASAN

Pengaruh besarnya nilai *epoch* pada klasifikasi citra daun tanaman padi pada arsitektur MobileNet menjadi bahan pokok penelitian ini. Dataset diambil dari kaggle.com pada tahun 2019 melibatkan 4 kelas sudah melalui proses anotasi sehingga tinggal menggunakan pada google colab. Arsitektur MobileNet membagi konvolusi layer menjadi 2 bagian yakni *depthwise* dan *pointwise* konvolusi [11].

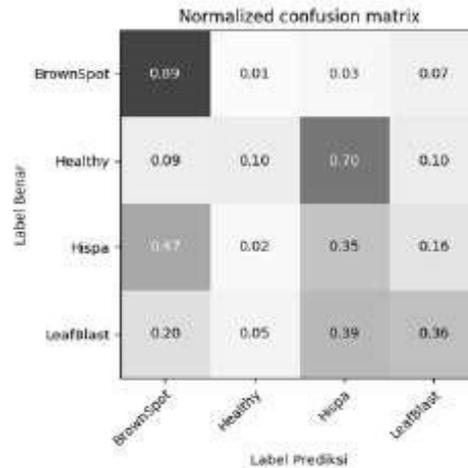
Rectifier Linier Unit (ReLU) sebagai fungsi aktivasi untuk menghilangkan nilai-nilai negatif pada hasil pooling. Proses pooling menggunakan maxpooling untuk mengurangi nilai pixel citra besar namun tidak mengurangi ciri dari citra tersebut. Pengulangan pooling dan konvolusi membuat citra menjadi lebih dikenali dan mampu mengurangi overfitting yang sering terjadi pada citra ukuran besar. Gambar 4 merupakan grafik hasil klasifikasi dengan 3 nilai Epoch yang berbeda (50,100,150) menghasilkan grafik yang berbeda. Pada epoch 50 (grafik 1a) menunjukkan grafik akurasi belum stabil pada angka 1 yang artinya tingkat akurasi belum bisa dijadikan acuan sebagai nilai akhir klasifikasi. Demikian pada bagian grafik loss dimana kesalahan akurasi dari awal epoch sampai epoch 50 menunjukkan tren penurunan yang artinya loss semakin berkurang namun belum menunjukkan nilai semestinya. Grafik 1b dan 1c menunjukkan pergerakan nilai akurasi yang semakin smooth dari epoch 1 hingga epoch

150 yang artinya epoch 150 menjadi lebih baik nilai akurasiya demikian juga dengan nilai loss. Akurasi mencapai nilai 1 saat epoch pada posisi 62 hingga epoch 150 dan nilai loss terkecil senilai 0,037 pada epoch 150.

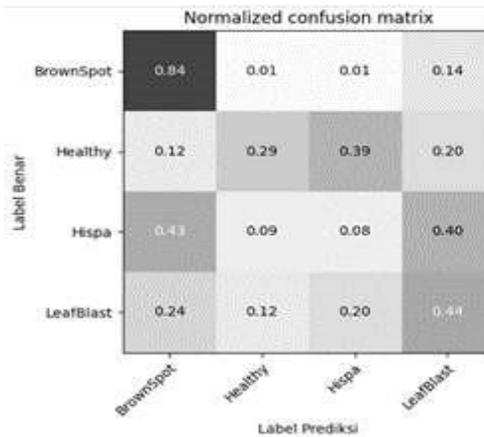


Gambar 4. Grafik Akurasi dan Kesalahan Pada Setiap Epoch (a) Epoch 50 (b) Epoch 10 (c) Epoch 150

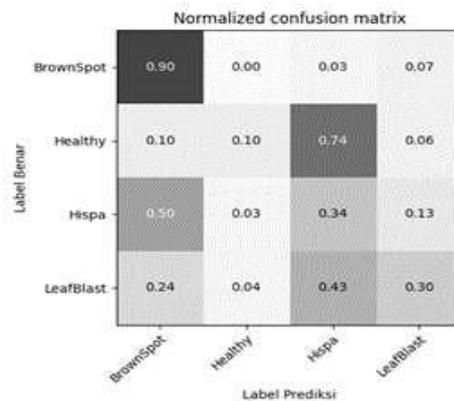
Sementara itu normalisasi dengan matriks konfusi menghasilkan perbandingan label prediksi dengan label aktual seperti pada gambar 5,6,7. Normalisasi ketiga nilai epoch menunjukkan adanya nilai lebih baik pada Epoch 150. Kelas Brownspot pada masing-masing epoch secara berurutan dari Epoch 50, 100 dan 150 menunjukkan nilai 0.89, 0.84 dan 0.90. Dengan demikian nilai epoch 150 menunjukkan hasil prediksi lebih baik dengan selisih 0.1



Gambar 5. Normalisasi pada Epoch 50

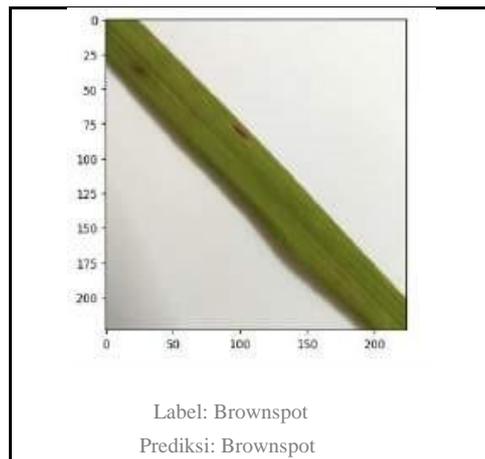


Gambar 6. Normalisasi pada Epoch 100



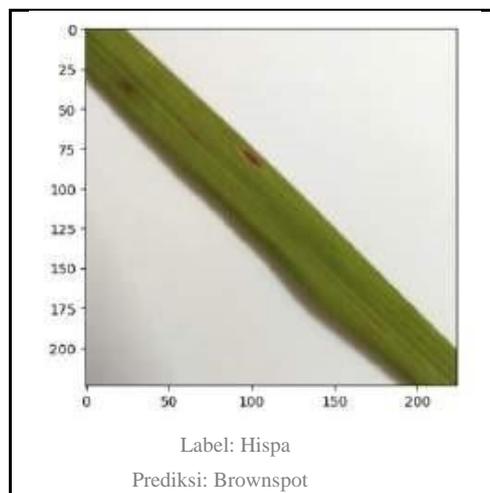
Gambar 7. Normalisasi pada Epoch 100

Proses epoch menunjukkan perlunya proses training dalam 1 putaran hingga di ulang ulang untuk mendapatkan nilai yang terbaik. Proses training tidaklah cukup jika hanya dilakukan sekali pada kumpulan dataset dengan jumlah ribuan karena itu perlu adanya sebuah looping training. Gambar 8 menunjukkan hasil prediksi dari hasil proses training pada epoch 50.



Gambar 8. Hasil Prediksi Sesuai Dengan Label

Prediksi tidak selalu sama dengan kelas yang ditentukan, adakalanya prediksi juga salah tidak sesuai dengan kelas. Gambar 9 menunjukkan kesalahan prediksi pada Epoch 150. Ketidaktepatan prediksi tidaklah menunjukkan adanya ketidaksesuaian arsitektur dan ketidaktepatan prediksi masih dalam tingkat kewajaran seperti ditunjukkan pada gambar 1.



Gambar 9. Kesalahan Prediksi Pada Epoch 150

Secara keseluruhan hasil prediksi dan loss dari epoch 50, 100 dan 150 disajikan dalam tabel 2. Dari ketiga nilai epoch terdapat nilai akurasi terbaik yakni pada epoch 150 namun pada epoch 150 juga terdapat loss namun masih pada tahap wajar dan menunjukkan semakin tinggi nilai epoch pada proses training akan mendapat nilai akurasi terbaik.

Tabel 2. Perbandingan Akurasi Pada *Epoch* 50,100 dan 150

Epoch	Training		Validasi	
	Akurasi	Loss	Akurasi	Loss
50	0,641	0,755	0.3345	17.085
100	0.9797	0.2280	0.3345	26.100
150	10.000	0.0037	0.3480	50.318

4. KESIMPULAN

Pengaruh epoch pada proses training akan mempengaruhi hasil akhir klasifikasi serta epoch dengan nilai tinggi akan menghasilkan tingkat akurasi paling baik. Sebagai kesimpulan akhir dari pengaruh epoch terhadap proses klasifikasi citra daun padi menggunakan arsitektur CNN MobileNet (1) Epoch 150 menghasilkan klasifikasi terbaik dengan akurasi sebesar 1.000 artinya akurasi mencapai 100% tepat pada dataset training. (2) Laos terbesar terjadi pada epoch 50 senilai 0.755 yang artinya proses training masih belum mendapatkan sebuah model yang tepat.

UCAPAN TERIMA KASIH

Penelitian ini terlaksana atas partisipasi beberapa pihak pendukung terutama pihak Erispro LPDP yang telah memberikan dukungan dana hibah pada skema Riset Keilmuan. Selain itu, kepada pihak LPPM Universitas Muhammadiyah Ponorogo sebagai regulator pelaksanaan penelitian dan pengabdian di lingkup Universitas Muhammadiyah Ponorogo. Sekali lagi kami ucapkan terima kasih kepada pihak-pihak yang telah membantu terlaksananya penelitian ini.

REFERENSI

- [1] Sudarma, Sritamin, dan Bagus, "Pengendalian Hama Dan Penyakit Tanaman Padi di Desa Pesaban, Kecamatan Rendang, Karangasem," *J. Udayana Mengabdikan*, vol. 15, no. September, pp. 106–112, 2016.
- [2] A. Prasetyo, Y. Litanianda, Moh. Bhanu Setyawan, F. Masykur, Sugianti, and Sumaji, "Pengendalian Suhu dan Kelembapan Kumbung Jamur Dengan Metode Fuzzy Terintegrasi Internet of Things," *Pros. ...*, 2021.
- [3] F. Masykur, A. Prasetyo, I. Widaningrum, A. F. Cobantoro, and M. B. Setyawan, "Application of Message Queuing Telemetry Transport (MQTT) Protocol on the Internet of Things to Monitor Mushroom Cultivation," *7th Int. Conf. Inf. Technol. Comput. Electr. Eng. ICITACEE 2020 - Proc.*, pp. 135–139, 2020.
- [4] T. R. Savera, W. H. Suryawan, and A. W. Setiawan, "Deteksi Dini Kanker Kulit Menggunakan K-Nn Dan Early Detection of Skin Cancer Using K-Nn and Convolutional," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 7, no. 2, pp. 373–378, 2020.
- [5] M. Syarief and W. Setiawan, "Convolutional neural network for maize leaf disease image classification," *Telkomnika (Telecommunication Comput. Electron. Control.)*, vol. 18, no. 3, pp. 1376–1381, 2020.

- [6] I. M. D. Maysanjaya, "Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 9, no. 2, pp. 190–195, 2020.
- [7] E. Sutoyo and M. A. Fadlurrahman, "Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Television Advertisement Performance Rating Menggunakan Artificial Neural Network," *J. Edukasi dan Penelit. Inform.*, vol. 6, no. 3, p. 379, 2020.
- [8] I. N. Purnama, "Herbal Plant Detection Based on Leaves Image Using Convolutional Neural Network with Mobile Net Architecture," *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 6, no. 1, pp. 27–32, 2020.
- [9] C. R. Rahman *et al.*, "Identification and recognition of rice diseases and pests using convolutional neural networks," *Biosyst. Eng.*, vol. 194, pp. 112–120, 2020.
- [10] A. Rajbongshi, T. Sarker, M. M. Ahamad, and M. M. Rahman, "Rose Diseases Recognition using MobileNet," *4th Int. Symp. Multidiscip. Stud. Innov. Technol. ISMSIT 2020 - Proc.*, 2020.