

Implementasi Hyperparameter Optimizer Pada InceptionV4 Untuk Deteksi Penyakit Karat Kedelai

IRMA AMELIA DEWI¹, MOHAMMAD GILANG G^{1*}

¹Program Studi Informatika, Institut Teknologi Nasional Bandung

Email : mohammadgilangg10@mhs.itenas.ac.id

Received 12 01 2023 | Revised 19 01 2023 | Accepted DD MM YYYY

ABSTRAK

Penyebab belum tercapainya target produksi kedelai di Indonesia karena adanya gangguan penyakit. Salah satu penyakit yang menyerang tanaman kedelai adalah penyakit karat. Karat adalah penyakit yang disebabkan oleh jamur *Phakopsora pachyrhizi*, penyakit ini menyerang daun dengan gejala berupa bercak berwarna coklat kemerahan mirip karat. Dengan perkembangan kecerdasan buatan terhadap computer vision saat ini, sudah banyak diterapkan dalam identifikasi gambar. Penelitian ini menggunakan deep learning dengan metode convolutional neural network (CNN) dengan arsitektur InceptionV4. InceptionV4 merupakan metode pengembangan dari versi sebelumnya, pada metode ini memperkenalkan *reduction block* yang digunakan untuk mengubah lebar dan tinggi grid. Hyperparameter yang digunakan pada penelitian ini yaitu optimizer Adam, dan RMSprop, learning rate 0.1 dan 0.01, batch size 32 dan 64, epoch 20 dan 50, dan dropout regularization. 5000 dataset yang digunakan untuk mengidentifikasi penyakit kedelai dengan rasio 80 : 20, data training 80% dan data testing 20%. Hasil akurasi yang diperoleh optimizer Adam adalah 88% dan RMSprop 90%.

Kata kunci: Kedelai, Karat, InceptionV4, Hyperparameters

ABSTRACT

The cause of not achieving the target of soybean production in Indonesia is due to disease disorders. One of the diseases that attack soybean plants is rust disease. Rust is a disease caused by the fungus Phakopsora pachyrhizi, this disease attacks the leaves with symptoms of reddish-brown spots resembling rust. With the development of artificial intelligence on computer vision today, it has been widely applied in image identification. This study uses deep learning with the convolutional neural network (CNN) method with the InceptionV4 architecture. InceptionV4 is a development method from the previous version, in this method it introduces a reduction block which is used to change the width and height of the grid. The hyperparameters used in this study were Adam optimizer and RMSprop, learning rates 0.1 and 0.01, batch sizes 32 and 64, epoch 20 and 50, and dropout regularization. 5000 datasets are used to identify soybean disease with a ratio of 80: 20, 80% training data and 20% testing data. The accuracy results obtained by the Adam optimizer are 88% and 90% RMSprop.

Keywords: Soybeans, Rust, InceptionV4, Hyperparameters

1. PENDAHULUAN

Kedelai merupakan salah satu komoditas tanaman pangan strategis dalam pembangunan sektor pertanian nasional bersama dengan komoditas padi dan jagung. Kedelai merupakan tanaman sumber protein yang murah, sehingga dapat digunakan untuk memenuhi kebutuhan gizi masyarakat **(Manik & Bangun, 2017)** Konsumsi kedelai di Indonesia sangat tinggi dibutuhkan sekitar 2.7 juta ton setiap tahun untuk memenuhi konsumsi dalam negeri, sedangkan produksi kedelai di Indonesia pada tahun 2021 hanya 200 ribu ton.

Salah satu penyebab rendahnya kualitas dan kuantitas kedelai adalah penyakit karat pada daun kedelai. Daun, bagian tanaman yang paling sensitif dan paling cepat menunjukkan gejala penyakit dibandingkan bagian lainnya **(kaur, pandey, & goel, 2018)**. Gejala awal penyakit karat pada kedelai ditandai dengan munculnya bercak klorotik kecil yang tidak beraturan pada permukaan daun **(Millenia, et al., 2021)**. Tanaman kedelai sangat rentan terhadap berbagai macam penyakit pada saat pertumbuhannya. Cara untuk mengidentifikasi penyakit pada tanaman kedelai, sebagian besar dilakukan oleh petani kedelai hanya dengan mengamati pada tampilan luar tanaman.

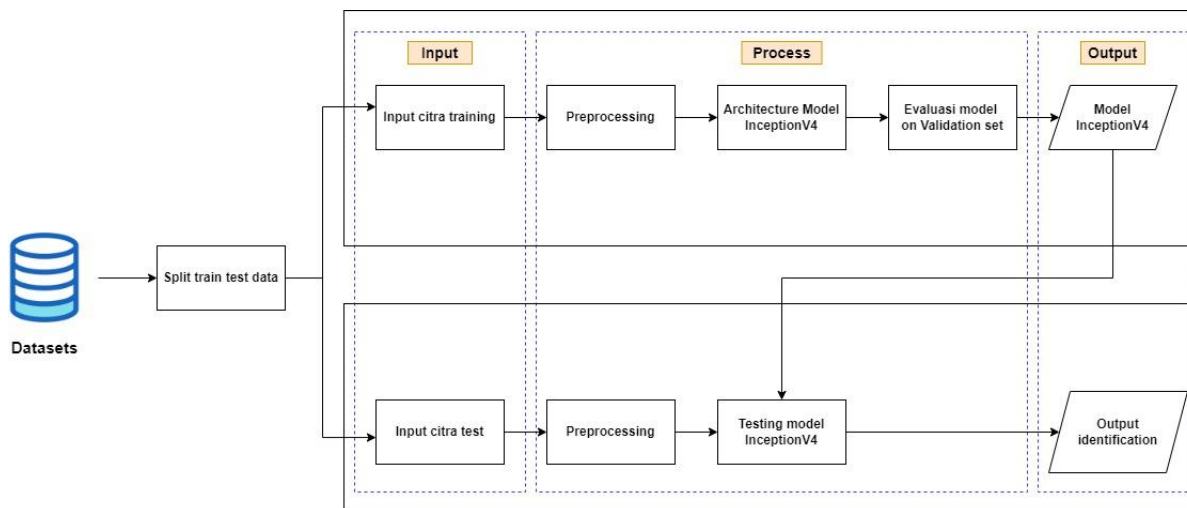
Pada penelitian sebelumnya sudah berhasil melakukan pengklasifikasian penyakit pada kedelai yaitu Penyakit karat daun, Down Mildew, dan pustul bakteri, dengan menggunakan metode Fuzzy K-Nearest Neighbor dan segmentasi metode Otsu, pada penelitian itu didapatkan nilai akurasi sebesar 83%.

Metode Deep learning adalah bidang penelitian yang sangat populer di banyak bidang, seperti ilmu komputer. Ini dapat diterapkan untuk mengatasi berbagai masalah, seperti transportasi, perawatan medis, pertanian, dan industri **(Chen, Wei, Xue, & Zhang, 2022)**. Pada penelitian kali ini akan menggunakan metode InceptionV4 dengan hyperparameter yang telah ditentukan untuk mendapatkan nilai akurasi terbaik. InceptionV4 adalah struktur jaringan saraf convolutional yang ditingkatkan dari generasi sebelumnya dari keluarga Inception dengan menyederhanakan desain dan menggunakan modul Inception tambahan dari pada InceptionV3. InceptionV4 yang berevolusi dari GoogleNet/InceptionV1, memiliki desain ramping yang lebih konsisten dan lebih banyak modul daripada InceptionV3. Jaringan ini memiliki banyak blok, termasuk blok stem, blok InceptionA, blok InceptionB, dan blok InceptionC, serta block reduksi **(Nazir, et al., 2022)**.

Kebaruan dari penelitian ini adalah memodifikasi hyperparameter yang digunakan yaitu optimizer Adam dan RMSprop, serta nilai epoch, learning rate, batch size, dan memanfaatkan dropout regularization untuk mengidentifikasi penyakit karat. Nilai dari epoch, learning rate, dan batch size akan dilakukan eksplorasi untuk mendapatkan model terbaik. Hyperparameter adalah preset numerik yang nilainya ditetapkan sebelum dimulainya proses pembelajaran. Memilih hyperparameter yang sesuai seringkali penting untuk mencapai kinerja yang memuaskan dalam banyak masalah penglihatan, seperti pelacakan objek visual berbasis pembelajaran mendalam **(Dong, Wang, Shao, Ling, & Porikli, 2019)**.

2. METODE PENELITIAN

Pada penelitian kali ini, Blok diagram pembuatan training model InceptionV4 dengan hyperparameter yang telah ditentukan untuk melakukan identifikasi penyakit karat daun pada tanaman kedelai, seperti diperlihatkan pada Gambar 1.



Gambar 1. Blok diagram sistem

Pada Gambar 1 blok diagram, diawali dengan proses input dataset lalu dataset tersebut di dibagi menjadi dataset training dan testing. Selanjutnya pada proses input training akan masuk ke proses sistem dengan preprocessing yaitu proses citra akan di resize dataset setelah di resize akan masuk ke proses sistem dengan arsitektur InceptionV4, didalam tahap proses akan dimasukan optimizer Adam dan RMSprop untuk mengurangi nilai error dan loss pada model, selanjutnya akan masuk ke evaluasi model yaitu proses dimana akan dilihat hasil dari akurasi yang dihasilkan, dan output dari proses training ini yaitu model yang telah disimpan. Untuk proses testing yaitu pertama memasukan citra test lalu masuk ke pre-processing dan akan melakukan testing model dari hasil training dan menghasilkan output berupa tag atau label keterangan dari citra apakah termasuk penyakit karat atau tidak.

2.1. Preprocessing dataset

Preprocessing dataset terdiri dari resize ukuran dataset, split dataset menjadi training dan testing, dan mengubah batch size dataset. Dataset diambil dari kaggle yang dibuat oleh Ma ELOISA Mignoni.

Tabel 1. Dataset

No	Soybean	Training data	Testing
1.	Rust	3314	693
2	Diabrotica Speciosa	2204	441
3.	Healthy	896	179
	Total	6.414	1.313

2.1.1 Resize dataset

Data yang telah dikumpulkan akan dilakukan proses resize menjadi ukuran 224 x 224 yang bertujuan untuk mengubah piksel gambar yang terdiri dari lebar gambar (width) dan tinggi gambar (height) yang akan digunakan pada percobaan kali ini.

2.1.2 Split dataset

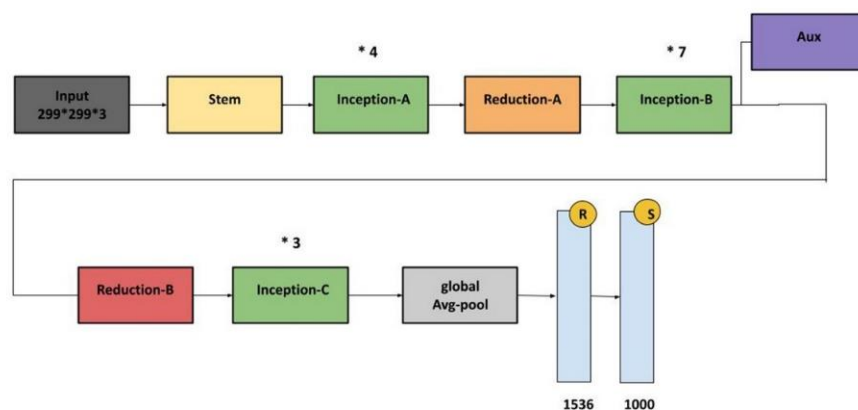
Split dataset bertujuan untuk membagi jumlah data dalam proses pembagian gambar. Pada penelitian kali ini nilai validasinya adalah 20%. Berarti 20% untuk dataset uji dan 80% untuk dataset latih. Dataset yang tepat dan besar diperlukan untuk semua pencarian klasifikasi selama tahap pelatihan dan pengujian **(Walleign, Polceanu, & Buche, 2018)**.

2.1.3 Processing

Processing merupakan proses pembuatan model yang terdiri dari ekstraksi fitur menggunakan InceptionV4 dan menentukan hyperparameter yang digunakan untuk menentukan nilai akurasi terbaik. Hyperparameter penting untuk algoritma pembelajaran mesin karena secara langsung mengontrol perilaku algoritma pelatihan dan memiliki pengaruh yang signifikan terhadap kinerja model pembelajaran mesin **(Wu, et al., 2019)**.

2.2 InceptionV4

InceptionV4 merupakan pengembangan dari versi sebelumnya, yaitu InceptionV3. InceptionV4 memiliki beberapa blok yaitu stem, A, B, dan C, InceptionV4 juga memiliki reduction block yang digunakan untuk mengubah lebar dan tinggi grid **(Wahid, Mustamin, & Lawi, 2021)**.



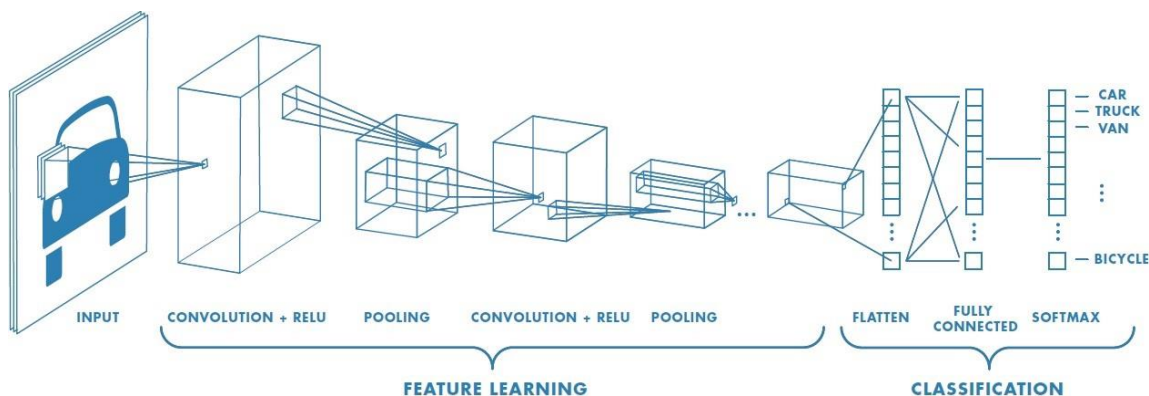
Gambar 2. Arsitektur InceptionV4 (Sumber : medium.com)

Metode InceptionV4 ini akan dikombinasikan dengan hyperparameter yang digunakan untuk mendapatkan nilai akurasi yang baik saat proses *training*. Optimizer yang digunakan yaitu Adam dan RMSprop, dan akan dilakukan eksplorasi nilai epoch, batch size, dan learning rate.

2.2.1 Convolutional Neural Network

Convolutional Neural Network adalah jaringan syaraf tiruan yang digunakan untuk melakukan pengenalan dan pemrosesan citra. CNN meniru cara sel saraf berkomunikasi dengan neuron yang saling berhubungan. Konsep CNN mirip dengan MLP, tetapi setiap neuron direpresentasikan dalam dua dimensi di CNN, sedangkan di MLP, setiap neuron

adalah satu dimensi (Simanjuntak, et al., 2022). Berikut adalah arsitektur jaringan saraf convolutional. CNN didasarkan pada tiga komponen utama: lapisan konvolusional, lapisan penyatuan, dan fungsi aktivasi, biasanya Rectified Linear Unit (ReLU). Jumlah lapisan yang digunakan, pengaturannya dan pengenalan unit pemrosesan lainnya bervariasi dari satu arsitektur ke arsitektur lainnya, menentukan kekhususannya (Boulet, Foucher, Theau, & St - Charles, 2019). Berikut arsitektur dari convolutional neural network Gambar 3.



Gambar 3. Arsitektur CNN (Sumber : medium.com)

3. HASIL DAN PEMBAHASAN

Kebaruan dari penelitian ini adalah pada proses training model menggunakan Google colab dengan mengimplementasikan optimizer Adam dan RMSprop, dan melakukan percobaan untuk mencari nilai terbaik dari epoch, learning rate, dan batch size dalam mencari model yang optimal pada arsitektur InceptionV4. Model optimal adalah model yang memiliki performa terbaik dalam melakukan proses training. Percobaan dilakukan dimulai dari epoch 10, 20, 50, dan 100, learning rate 0.01 dan 0.1, dan batch size 32 dan 64. Dari hasil percobaan tersebut didapatkan nilai terbaik dengan epoch 20 dan 50, learning rate 0.01 dan 0.1, batch size 32 dan 64, dan dropout regularization untuk menghindari overfitting. Dropout adalah teknik yang ampuh dan banyak digunakan untuk mengatur pelatihan deep learning (Liang, et al., 2021).

3.1 Pengujian optimizer Adam dan RMSprop

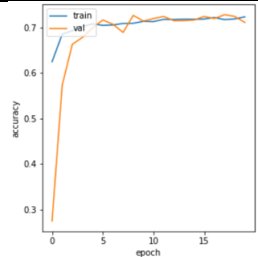
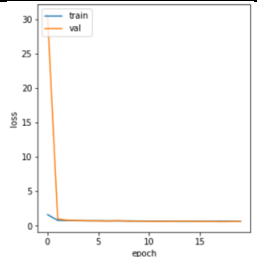
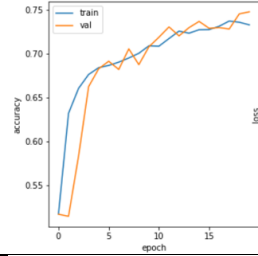
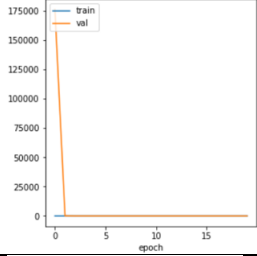
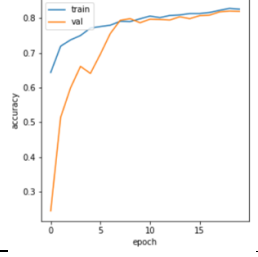
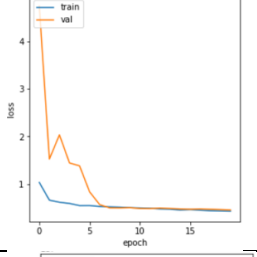
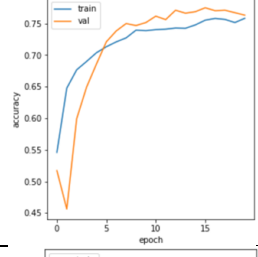
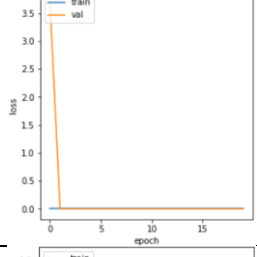
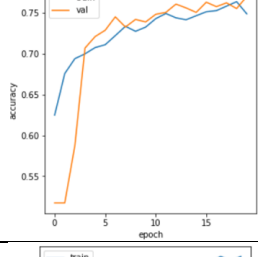
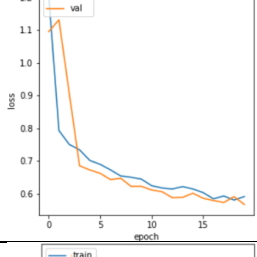
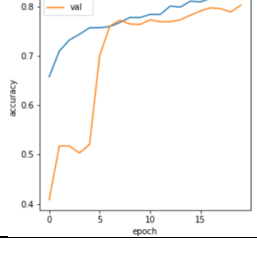
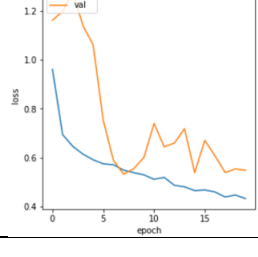
Pengujian model dilakukan dengan parameter epoch 20 , Optimizer Adam dan RMSprop, batch size 32 dan 64, dan learning rate 0.1 dan 0.01. Berikut adalah hasil dari pengujian tersebut :

Tabel 2. Hasil Pengujian epoch 20

No	Epoch	Batch Size	Learning rate	Optimizer	Akurasi
1	20	32	0.1	Adam	0.75
2	20	64	0.1	Adam	0.74
3	20	32	0.1	RMSprop	0.81
4	20	64	0.1	RMSprop	0.76
5	20	32	0.01	Adam	0.84
6	20	64	0.01	Adam	0.80
7	20	32	0.01	RMSprop	0.80
8	20	64	0.01	RMSprop	0.82

Pengujian dilakukan dengan pola 4 kali percobaan optimizer Adam dan RMSprop yang masing – masing memiliki nilai epoch, batch size, dan learning rate yang berbeda – beda. Hasil dari pengujian dengan hyperparameter diatas menghasilkan grafik yang berbeda – beda setiap percobaan, seperti diperlihatkan pada Tabel 3.

Tabel 3. Grafik akurasi dan loss

Hyperparameter	Accuracy	Loss	Grafik Accuracy	Grafik Loss
OP : Adam Batch Size : 32 Learning rate : 0.1	0.75	0.64		
OP : Adam Batch Size : 64 Learning rate : 0.1	0.74	0.64		
OP : RMSprop Batch Size : 32 Learning rate : 0.1	0.81	0.52		
OP : RMSprop Batch Size : 64 Learning rate : 0.1	0.76	1.35		
OP : Adam Batch Size : 32 Learning rate : 0.01	0,84	0.43		
OP : Adam Batch Size : 64 Learning rate : 0.01	0.80	0.55		

Tabel 3. Grafik akurasi dan loss (Lanjutan)

Hyperparameter	Accuracy	Loss	Grafik Accuracy	Grafik Loss
OP : RMSprop Batch Size : 32 Learning rate : 0.01	0.80	0.51		
OP : RMSprop Batch Size : 64 Learning rate : 0.01	0.82	0.45		

3.2 Pengujian optimizer Adam dan RMSprop

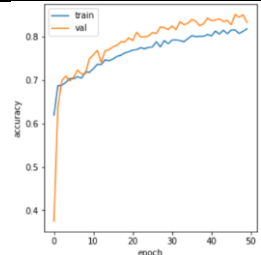
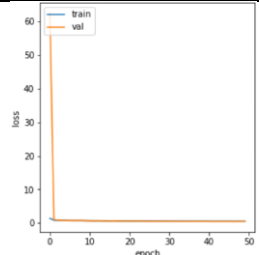
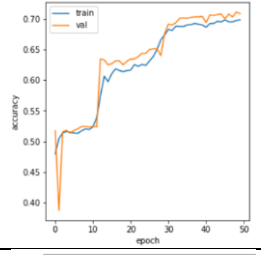
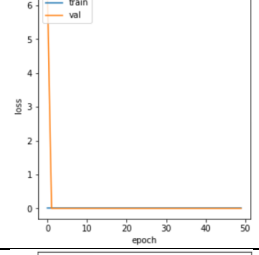
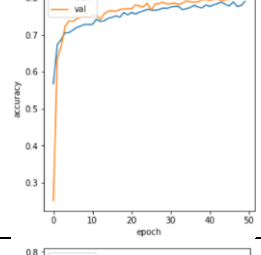
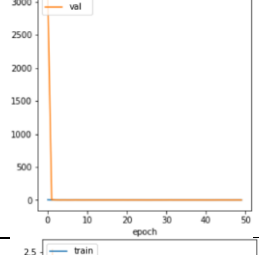
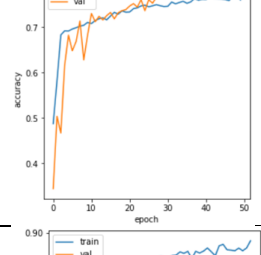
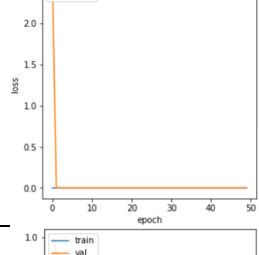
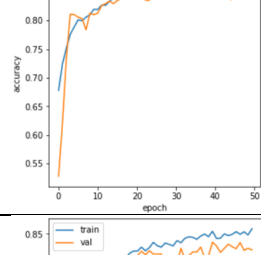
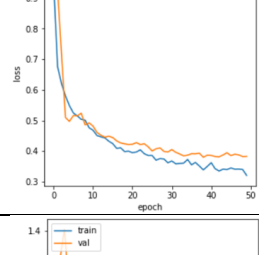
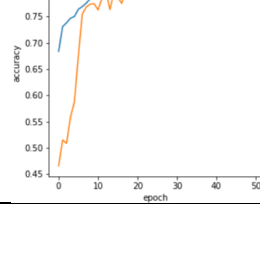
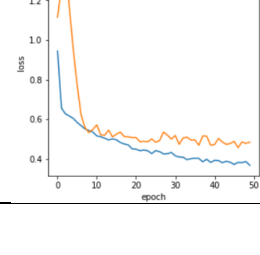
Pengujian model dilakukan dengan parameter epoch 50 , Optimizer Adam dan RMSprop, batch size 32 dan 64, dan learning rate 0.1 dan 0.01. Berikut adalah hasil dari pengujian tersebut :

Tabel 4. Hasil pengujian epoch 50

No	Epoch	Batch Size	Learning rate	Optimizer	Akurasi
1	50	32	0.1	Adam	0.83
2	50	64	0.1	Adam	0.70
3	50	32	0.1	RMSprop	0.79
4	50	64	0.1	RMSprop	0.77
5	50	32	0.01	Adam	0.84
6	50	64	0.01	Adam	0.81
7	50	32	0.01	RMSprop	0.86
8	50	64	0.01	RMSprop	0.80

Pengujian kedua dengan hyperparameter diatas menghasilkan grafik yang berbeda – beda setiap percobaan, seperti yang diperlihatkan pada Tabel 5.

Tabel 5. Hasil grafik akurasi dan loss

Hyperparameter	Accuracy	Loss	Grafik Accuracy	Grafik Loss
OP : Adam Batch Size : 32 Learning rate : 0.1	0.83	0.45		
OP : Adam Batch Size : 64 Learning rate : 0.1	0.70	0,71		
OP : RMSprop Batch Size : 32 Learning rate : 0.1	0.79	1.03		
OP : RMSprop Batch Size : 64 Learning rate : 0.1	0.77	1.44		
OP : Adam Batch Size : 32 Learning rate : 0.01	0.84	0.38		
OP : Adam Batch Size : 64 Learning rate : 0.01	0.81	0.48		

Tabel 5. Hasil grafik akurasi dan loss (Lanjutan)

Hyperparameter	Accuracy	Loss	Grafik Accuracy	Grafik Loss
OP : RMSprop Batch Size : 32 Learning rate : 0.01	0.86	0.37		
OP : RMSprop Batch Size : 64 Learning rate : 0.01	0.80	0.48		

Untuk Tabel 3 dan Tabel 4 menunjukkan hasil yang tidak jauh berbeda dari percobaan epoch 20, percobaan ini menggunakan hyperparameter epoch 50 dan menghasilkan nilai akurasi terbaik yaitu 0.86% dan nilai loss 0.37%.

4. KESIMPULAN

Pada penelitian ini diketahui bahwa pada daun tanaman kedelai ada beberapa penyakit yang mengakibatkan kurangnya hasil panen kedelai, salah satunya penyakit karat yang menyerang pada daun kedelai. Dengan adanya penelitian ini diharapkan bisa mengidentifikasi penyakit yang ada di tanaman kedelai, InceptionV4 telah melakukan kerjanya dengan baik dan menghasilkan tingkat akurasi 86%. Hyperparameter yang digunakan seperti epoch, batch size, learning rate, dan optimizer berhasil membuat akurasi menjadi lebih baik. Untuk penelitian selanjutnya diharapkan melakukan beberapa eksperimen saat training model agar bisa menghasilkan model yang lebih baik.

UCAPAN TERIMA KASIH

Penelitian ini didukung oleh Irma Amelia Dewi, S.Kom., M.T. selaku pembimbing dalam penulisan penelitian ini dan keluarga yang telah menjadi motivasi dalam menyelesaikan penelitian ini. Dalam proses penyusunan penelitian masih banyak kekurangan dan kesalahan. Oleh karena itu, penulis menerima segala masukan dan saran yang bersifat membangun dari berbagai pihak. Semoga peneliti dan pembaca dapat membagikan ilmu yang didapat dan diberikan amal baik yang setimpal oleh Allah SWT.

DAFTAR PUSTAKA

- Manik, F. Y., & Bangun, M. B. (2017). IDENTIFIKASI HAMA PADA TANAMAN KEDELAH DENGAN MENGGUNAKAN METODE FUZZY. *Jurnal Sistem Informasi Kaputama(JSIK)*, 8.
- kaur, S., pandey, S., & goel, S. (2018). Semi-automatic leaf disease detection and classification system for soybean culture. *The Institution of Engineering and Technology*, 11.
- Millenia, H. T., Febrianty, A., Lussy, A. D., Nurhasanah, I., Yunitasari, N., Priyanti, & Junaidi. (2021). Jenis-Jenis Penyakit Pada Tanaman Kedelai (Glycine max) Serta Pengendaliannya Secara Fisik dan Kimia. *Universitas Negeri Padang*, 13.
- Chen, F., Wei, J., Xue, B., & Zhang, M. (2022). Feature fusion and kernel selective in Inception-v4 network . *ScienceDirect*.
- Nazir, M. S., Khan, U. G., Mohiyuddin, A., Reshan, M. S., Shaikh, A., Rizwan, M., & Davidekova, M. (2022). A Novel CNN-Inception-V4-Based Hybrid Approach for Classification of Breast Cancer in Mammogram Images. *Hindawi*.
- Dong, X., Wang, W., Shao, L., Ling, H., & Porikli, F. (2019). Dynamical Hyperparameter Optimization via Deep Reinforcement Learning in Tracking. *IEEE Xplore*.
- Walleign, S., Polceanu, M., & Buche, C. (2018). Soybean Plant Disease Identification Using Convolutional Neural Network. *The Thirty-First International Floradi*, 6.
- Wu, J., Chen, X. Y., L, H. Z., Xiong, L. D., L, H. L., & Deng 2, S. H. (2019). Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization. *KeAi*, 15.
- Wahid, M. I., Mustamin, S. A., & Lawi, A. (2021). Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur InceptionV4. *Konferensi Nasional Ilmu Komputer 2021*, 8.
- Simanjuntak, R. B., Adah, Y. F., Magdalena, R., Saidah, S., Wiratama, A. B., & Ubaidah, I. D. (2022). Cataract Classification Based on Fundus Images Using Convolutional Neural Network . *International Journal On Informatics Visualization*, 6.
- Boulent, J., Foucher, S., Theau, J., & St - Charles, P. L. (2019). Convolutional Neural Networks for the Automatic Identification of Plant Diseases. *frontiers*.
- Liang, X., Wu, L., Li, J., Wang, Y., Meng, Q., Qin, T., . . . Liu, T. Y. (2021). R-Drop: Regularized Dropout for Neural Networks. *NeurIPS*, 16.