

Implementasi Transfer Learning pada Algoritma Convolutional Neural Network Untuk Identifikasi Penyakit Daun Kentang

Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease

1st Abdul Jalil Rozaqi¹, 2nd Andi Sunyoto², 3rd Muhammad Rudyanto Arief³
{abdul.13@students.amikom.ac.id¹, andi@amikom.ac.id², rudy@amikom.ac.id³}

Magister of Informatics Engineering, University of Amikom Yogyakarta^{1,2,3}

Abstract. Potatoes are a plant that has many benefits for human life. The potato plant has a problem, namely a disease that attacks the leaves. Disease on potato leaves that is often encountered is early blight and late blight. Image processing is a method that can be used to assist farmers in identifying potato leaf disease by utilizing leaf images. Image processing method development has been done a lot, one of which is by using the Convolutional Neural Network (CNN) algorithm. The CNN method is a good image classification algorithm because its layer architecture can extract leaf image features in depth, however, determining a good CNN architectural model requires a lot of data. CNN architecture will become overfitting if it uses less data, where the classification model has high accuracy on training data but the accuracy becomes poor on test data or new data. This research utilizes the Transfer Learning method to avoid an overfit model when the data used is not ideal or too little. Transfer Learning is a method that uses the CNN architecture that has been trained by other data previously which is then used for image classification on the new data. The purpose of this research was to use the Transfer Learning method on CNN architecture to classify potato leaf images in identifying potato leaf disease. This research compares the Transfer Learning method used to find the best method. The results of the experiments in this research indicate that the Transfer Learning VGG-16 method has the best classification performance results, this method produces the highest accuracy value of 95%.

Keywords –leaf disease; early blight; late blight; CNN; transfer learning


Abstrak. Kentang adalah tanaman yang memiliki banyak manfaat bagi kehidupan manusia. Pertanian kentang memiliki masalah berupa penyakit yang menyerang pada daun. Penyakit pada daun kentang yang sering ditemui adalah early blight dan late blight. Image processing adalah metode yang dapat digunakan untuk membantu petani dalam mengidentifikasi penyakit pada daun kentang dengan memanfaatkan citra daun. Pengembangan image processing telah banyak dilakukan salah satunya adalah dengan menggunakan algoritma Convolutional Neural Network (CNN). Metode CNN merupakan algoritma klasifikasi citra yang bagus dikarenakan arsitektur lapisannya yang dapat mengekstraksi fitur citra daun secara mendalam, akan tetapi dalam menentukan model arsitektur CNN yang baik diperlukan data yang besar dan ideal. Arsitektur CNN akan mengalami overfitting jika menggunakan data yang sedikit, dimana model klasifikasi memiliki akurasi yang tinggi pada data latih tetapi akurasinya menjadi buruk pada data uji atau data baru. Penelitian ini memanfaatkan metode Transfer Learning untuk menghindari overfit pada data yang tidak cukup ideal atau terlalu sedikit. Transfer Learning merupakan metode yang menggunakan arsitektur CNN yang sudah dilatih oleh data lain sebelumnya yang kemudian digunakan untuk klasifikasi citra pada data yang baru. Metode Transfer Learning yang digunakan pada penelitian ini adalah VGG-16, Inception-V3 dan ResNet-50. Penelitian ini membandingkan metode Transfer Learning yang digunakan untuk mencari metode yang terbaik. Hasil dari uji coba pada penelitian ini menghasilkan bahwa metode Transfer Learning VGG-16 memiliki hasil performa klasifikasi yang terbaik dan menghasilkan nilai akurasi tertinggi sebesar 95%.

Kata Kunci –penyakit daun; early blight; late blight; CNN; transfer learning

I. PENDAHULUAN

Tanaman kentang adalah tanaman yang memiliki banyak manfaat bagi keberlangsungan kehidupan manusia. Kentang merupakan salah satu makanan yang mengandung karbohidrat yang merupakan bahan penting bagi manusia untuk menghasilkan energi sehingga kentang termasuk makanan pokok manusia [1], selain itu kentang mengandung beberapa nutrisi penting yang dibutuhkan tubuh manusia yaitu vitamin C, kalium dan serat makanan [2]. Kentang juga merupakan salah satu bahan penting dalam industri pangan [3]. Pengembangan pada pertanian tanaman kentang menjadi penting mengingat banyaknya manfaat yang dimiliki oleh kentang [4], tetapi pengembangan pertanian tanaman kentang memiliki beberapa masalah yang berakibat fatal diantaranya adalah jenis penyakit yang menyerang pada daun kentang dimana penyakit ini menghambat produksi tanaman kentang [5].

Penyakit pada tanaman kentang yang paling banyak ditemui adalah penyakit bercak daun (*early blight*) [6] dan penyakit busuk daun (*late blight*) dimana penyakit ini memiliki sifat merusak daun yang berakibat merusak pertanian tanaman kentang [5]. Penyebab terjadinya penyakit bercak daun (*early blight*) adalah jamur *Alternaria Solani* [6]. *Early blight* memiliki gejala awal ditandai dengan bercak-bercak melingkar di bagian tengah daun dan bisa juga pada bagian tepi daun seperti yang ditunjukkan pada Gambar 1 (a) penyakit ini dapat terus menyebar hingga merusak daun tanaman. *Microbe Phytophthora infestans de Bary*, tempat dingin dan lembab adalah faktor penyakit busuk daun (*late blight*) berkembang [7]. Gambar 1 (b) menunjukkan penyakit busuk daun (*late blight*) pada daun tanaman kentang. Penyakit ini memiliki gejala awal ditandai dengan munculnya lesi berwarna hitam atau kecoklatan pada bagian tepi daun ataupun pada bagian tengah daun yang kemudian akan terus merambat hingga merusak tanaman.



Gambar 1. Penyakit pada daun kentang (a) *early blight* (b) *late blight*

Gejala awal dari penyakit pada daun kentang ini dapat dimanfaatkan untuk melakukan pencegahan oleh para petani supaya tidak menular ke daun yang masih sehat. Pencegahan meluasnya penyakit pada daun kentang ini memiliki kendala karena hanya dapat dilakukan jika para petani memiliki pengetahuan yang luas tentang penyakit ini [5]. Penanganan penyakit pada daun tanaman ini perlu dilakukan secara cepat dan tepat untuk mencegah penurunan produksi tanaman kentang [8]. Permasalahan ini dapat diatasi dengan pemanfaatan *image processing* yang dapat digunakan untuk mendeteksi perbedaan jenis daun dengan menggunakan data citra yang telah dikumpulkan sebagai rujukannya [9].

Pemanfaatan *image processing* untuk mengidentifikasi sebuah objek dengan memanfaatkan data citra yang sudah ada telah banyak dilakukan, penelitian [10] melakukan segmentasi warna untuk mendapatkan bagian yang penting pada citra daun. Daun tanaman memiliki perbedaan tekstur yang berbeda-beda, maka untuk melakukan klasifikasi dapat menggunakan tekstur ini sebagai bahan informasi seperti yang dilakukan pada penelitian [11] yang melakukan ekstraksi fitur tekstur yang dimiliki oleh citra daun dengan menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM). Jumlah data yang dimiliki untuk melakukan klasifikasi juga mempengaruhi tingkat ketepatan dalam mengidentifikasi objek [12]. Penelitian [13] memakai metode *Convolutional Neural Network* (CNN) untuk melakukan deteksi penyakit pada daun tomat dengan 6000 data, metode CNN memiliki kelebihan pada fitur ekstraksi ciri yang dimiliki citra pada lapisan convolution nya dan hasil akurasi dari penelitian ini adalah 96%. Klasifikasi jenis tanaman dengan menggunakan metode *Convolutional Neural Network* (CNN) pada penelitian [14] mendapatkan tingkat akurasi 100% pada data *training*, tetapi tingkat akurasi pada data *validation* sebesar 93% dan tingkat akurasi pada data *testing* 82%, peneliti menerangkan bahwa penggunaan data yang sedikit dan kurangnya variasi dari citra yang digunakan sangat mempengaruhi hasil klasifikasi. Kasus akurasi data *training* lebih besar dari akurasi data *testing* masuk kedalam jenis model *overfitting* dimana proses klasifikasi terlalu berfokus kepada data *training* yang dimiliki.

CNN adalah metode yang sangat bagus dengan ekstraksi fiturnya yang mampu menangani klasifikasi citra secara baik [15][16], CNN sangat cocok untuk klasifikasi pada jumlah data yang besar seperti pada penelitian deteksi jenis buah [17], klasifikasi penyakit daun tomat[13], klasifikasi penyakit daun kentang [18]. Namun data yang didapatkan untuk digunakan dalam melakukan klasifikasi citra tidak semuanya selalu memiliki jumlah data yang besar, data yang didapatkan bisa saja memiliki proporsi yang tidak seimbang untuk setiap label nya dan ini mempengaruhi tingkat akurasi yang dihasilkan pada proses klasifikasi.

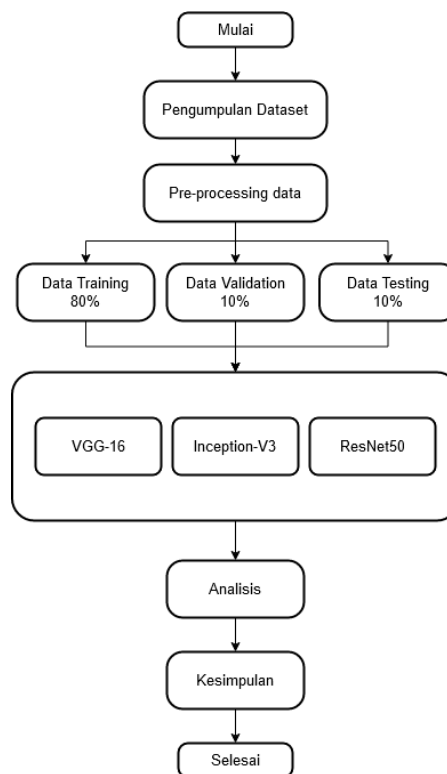
Solusi dalam mengatasi data yang sedikit pada klasifikasi dengan *Convolutional Neural Network* adalah dengan menggunakan model *transfer learning* pada arsitektur CNN, model transfer learning atau biasa disebut juga *pre-trained model* adalah arsitektur CNN yang sudah dilatih dengan suatu dataset sebelumnya yang nantinya bisa digunakan untuk melatih dataset lain [19]. Model *Transfer Learning* CNN memiliki perbedaan pada tingkat

kedalaman lapisan dibandingkan CNN sederhana. Model *transfer learning* memiliki beberapa jenis diantaranya adalah VGG-16 [20], Inception-V3 [21], ResNet-50 [22] dan masih banyak model *transfer learning* yang lainnya.

Penelitian ini akan melakukan klasifikasi penyakit pada daun kentang dengan menggunakan arsitektur *Convolutional Neural Network* (CNN). Data yang digunakan pada penelitian ini memiliki jumlah yang sedikit, permasalahan yang bisa muncul ketika menggunakan data yang kurang banyak adalah terjadinya *overfitting* [23], sehingga pada penelitian ini akan menggunakan model *transfer learning* arsitektur CNN untuk mengatasi masalah data yang sedikit. Kelebihan dari metode *Transfer Learning* adalah kemampuannya dalam menghasilkan informasi yang lebih banyak untuk klasifikasi karena memiliki lapisan yang lebih mendalam dibandingkan CNN sederhana. Penelitian ini menggunakan model *transfer learning* VGG-16, Inception-V3 dan ResNet-50 untuk mencari model *transfer learning* yang cocok dengan akurasi tertinggi dalam menangani data yang sedikit.

II. METODE

A. Kerangka Penelitian



Gambar 2. Kerangka Penelitian

Kerangka penelitian untuk identifikasi penyakit pada daun kentang dapat dilihat pada Gambar 2, ada beberapa tahapan dalam melakukan identifikasi dengan menggunakan model *transfer learning* pada metode *Convolutional Neural Network* (CNN). Tahap awal dimulai dari pengumpulan data yang digunakan, kemudian melakukan *pre-processing* data yaitu merubah ukuran citra dan membagi dataset yang digunakan ke data *training*, *validation* dan data *testing*. Tahap selanjutnya adalah proses klasifikasi dengan *transfer learning*, kemudian hasil dari klasifikasi akan dianalisis untuk mengetahui model *transfer learning* pada metode CNN yang terbaik dalam mengidentifikasi penyakit pada daun kentang.

B. Dataset

Tabel 1. Detail dataset citra daun kentang

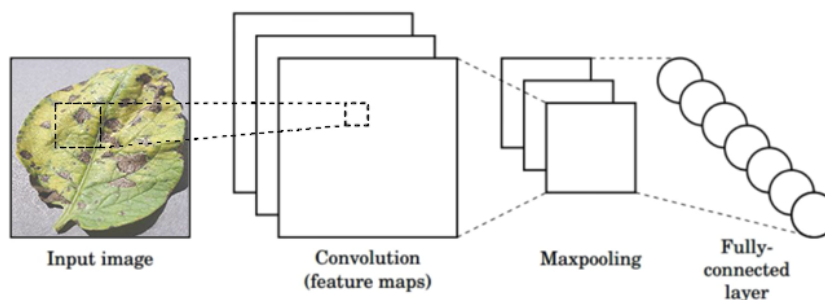
Sampel Data	Jumlah	Sumber
Early blight	150	Website kaggle
Late blight	150	(Plantvillage)
Daun sehat	150	
Total	450	

Bahan yang digunakan untuk identifikasi penyakit daun kentang pada penelitian ini adalah data citra daun kentang yang didapatkan dari website kaggle dengan nama *Plant Village*[24]. Data citra yang digunakan dibagi menjadi 3 kelas yaitu data citra daun penyakit *early blight*, data citra daun penyakit *late blight* dan data citra daun sehat. Data yang ditemui memiliki jumlah yang tidak seimbang yang apabila digunakan dapat mempengaruhi performa model klasifikasi, maka jumlah data yang digunakan di sama ratakan seperti yang terlihat pada Tabel 1.

C. Preprocessing Data

Tahap persiapan atau *preprocessing* data adalah mengolah data asli supaya bisa siap digunakan pada model klasifikasi. *Preprocessing* data pada penelitian ini adalah merubah ukuran citra ke ukuran 150x150 piksel untuk lebih mempercepat proses klasifikasi. Dataset kemudian dibagi menjadi 3 bagian untuk dimasukkan kedalam model klasifikasi, perincian pembagian data ini adalah 80% untuk data *training* yaitu data yang digunakan untuk melatih model klasifikasi, 10% untuk data *validation* yaitu data untuk memvalidasi model klasifikasi untuk menghindari terjadinya *overfitting*, dan 10% untuk data *testing* yaitu data yang digunakan untuk menguji ketepatan model klasifikasi.

D. Proses Klasifikasi

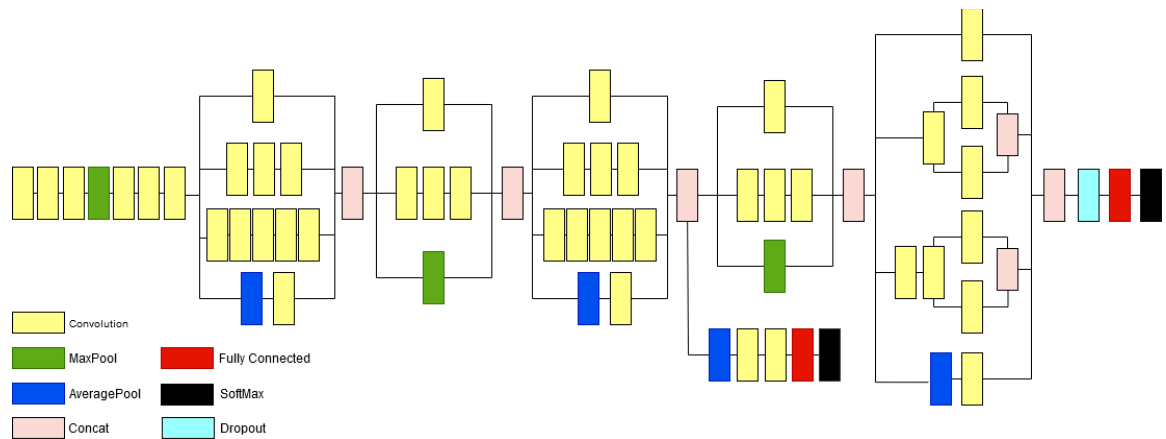


Gambar 3.Contoh arsitektur *Convolutional Neural Network (CNN)*


Proses klasifikasi pada arsitektur *Convolutional Neural Network (CNN)* memiliki beberapa lapisan. Gambar 3 menjelaskan contoh lapisan sederhana arsitektur CNN untuk proses identifikasi, tahap pertama adalah lapisan *convolution* yang merupakan lapisan utama pada CNN yang akan melakukan ekstraksi tekstur dari citra daun yang digunakan. Hasil dari ekstraksi pada lapisan *convolution* akan dilakukan *pooling* untuk mengurangi ukuran piksel citra tanpa mengurangi kualitasnya, *pooling* yang biasa digunakan adalah *Max Pooling* atau *Average pooling*. Tahap akhir adalah pada *fully connected layer*, pada layer ini hasil dari proses *convolution* dan *pooling* akan digunakan untuk klasifikasi. Model arsitektur CNN yang baik didapat dengan penataan tingkat kedalaman dan jumlah lapisan *convolution* dan *pooling* yang digunakan.

E. Transfer Learning


Transfer learning merupakan model arsitektur CNN yang sudah dilatih oleh suatu dataset sebelumnya yang bisa digunakan untuk klasifikasi pada dataset lain [19]. *Transfer learning* memiliki arsitektur lapisan *convolution* dan *pooling* yang lebih dalam dibandingkan arsitektur CNN sederhana, sehingga dapat melakukan ekstraksi tekstur citra lebih banyak dan menghasilkan informasi dari citra yang lebih baik.



Gambar 4. Model Inception-V3



Gambar 5. Model VGG-16



Gambar 6. Model ResNet-50


Kedalaman lapisan arsitektur pada *Transfer Learning* yang membuat metode ini bisa mengatasi *overfit* pada data yang sedikit. Penelitian ini akan menggunakan model *Transfer Learning* Inception-V3, VGG-16 dan ResNet-50 yang memiliki tingkat kedalaman lapisan yang berbeda-beda. Gambar 4 adalah susunan arsitektur dari model *Transfer Learning* Inception-V3, pada arsitektur ini memiliki lapisan yang lebih dalam dibandingkan dengan arsitektur CNN sederhana. Gambar 5 adalah susunan arsitektur untuk model *Transfer Learning* VGG-16, dan yang terakhir Gambar 6 adalah susunan arsitektur dari model *Transfer Learning* ResNet-50.

Penelitian ini akan melakukan analisa model *Transfer Learning* mana yang terbaik dalam melakukan klasifikasi daun yang sehat dan daun yang memiliki penyakit. Proses analisa untuk mencari model yang terbaik pada penelitian ini menggunakan metode pengujian *Confusion Matrix*. Pengujian metode *Confusion Matrix* menggunakan hasil data yang diprediksi oleh model klasifikasi dengan data yang sesungguhnya [25][26].

III. HASIL DAN PEMBAHASAN

Penelitian ini melakukan beberapa percobaan sesuai tahapan pada kerangka penelitian, percobaan pertama adalah dengan menggunakan arsitektur CNN sederhana untuk klasifikasi citra daun, kemudian dilakukan percobaan dengan menggunakan arsitektur model *transfer learning*.

A. Hasil Klasifikasi dengan Arsitektur CNN Sederhana




Gambar 7. Hasil dari model klasifikasi CNN sederhana (a) akurasi (b) *loss*

Gambar 7 menunjukkan grafik performa hasil akurasi dan *loss* dari arsitektur CNN sederhana, dimana garis biru untuk data *training* dan warna oranye untuk data *validation*. Hasil klasifikasi menunjukkan bahwa model arsitektur yang digunakan mengalami *overfitting* seperti yang ditampilkan pada Gambar 7 akurasi untuk data *training* memiliki perbedaan yang besar dengan data *validation*. Hasil dari percobaan ini jelas bahwa dengan menggunakan arsitektur CNN yang sederhana menghasilkan performa model klasifikasi yang tidak baik.


B. Hasil Klasifikasi dengan Transfer Learning

Percobaan selanjutnya adalah melakukan klasifikasi dengan menggunakan model *Transfer Learning* Inception-V3, VGG-16 dan ResNet-50.




Gambar 8. Hasil dari klasifikasi model *transfer learning* Inception-V3 (a) akurasi (b) *loss*

Gambar 8 adalah grafik dari hasil klasifikasi menggunakan model *transfer learning* Inception-V3 yang mana nilai akurasi dan *loss* pada data *training* dan data *validation* mengalami lonjakan naik turun yang tidak stabil. Hasil klasifikasi pada data *training* dan data *validation* menggunakan model *transfer learning* Inception-V3 menunjukkan performa yang kurang baik.



Gambar 9. Hasil dari klasifikasi model *transfer learning* VGG-16 (a) akurasi (b) *loss*

Hasil klasifikasi pada data *training* dan data *validation* menggunakan model *transfer learning* VGG-16 menunjukkan performa yang baik seperti yang ditunjukkan pada Gambar 9 nilai akurasi pada data *training* dan data *validation* meningkat secara stabil dan nilai *loss* pada data *training* dan data *validation* menurun secara stabil. Grafik pada Gambar 9 menunjukkan nilai akurasi dan *loss* pada data *training* dan data validasi tidak memiliki perbedaan yang lebar.




Gambar 10. Hasil dari klasifikasi model *transfer learning* ResNet-50 (a) akurasi (b) *loss*

Gambar 10 merupakan grafik dari hasil klasifikasi pada data *training* dan data *validation* menggunakan model *transfer learning* ResNet-50. Hasil pada grafik menunjukkan bahwa nilai akurasi dan *loss* pada data *training* dan data *validation* memiliki perbedaan yang lebar. Perbedaan nilai yang lebar antara nilai akurasi dan *loss* merupakan bukti bahwa performa klasifikasi mengalami *overfitting* dan ini adalah hasil yang kurang baik dari model klasifikasi.

C. Pengujian dengan Confusion Matrix

Tahap terakhir adalah melakukan pengujian model klasifikasi pada data *testing* dan dianalisa menggunakan Confusion Matrix. Hasil pengujian dengan menggunakan *Confusion Matrix* dapat dilihat pada Gambar 11, untuk menghitung tingkat akurasi dari pengujian menggunakan metode ini adalah dengan cara membandingkan nilai data yang diprediksi benar dengan seluruh jumlah data yang digunakan.



Gambar 11. Confusion Matrix (a) CNN Sederhana (b) Inception-V3 (c) VGG-16 (d) ResNet-50

Hasil pengujian dengan *confusion matrix* pada Gambar 11 dapat dilihat memiliki 3 kelas berupa Early untuk penyakit *early blight*, kelas Healthy untuk daun sehat, dan kelas Late untuk penyakit *late blight*.

Tabel 2. Perbandingan hasil akurasi dari pengujian dengan menggunakan Confusion Matrix

Model Klasifikasi	Prediksi Benar	Prediksi Salah	Akurasi
CNN Sederhana	36	9	80%
Inception-V3	35	10	78%
VGG-16	43	2	95%
ResNet-50	35	10	78%

Tabel 2 merupakan hasil perbandingan dari nilai akurasi yang didapatkan dengan menggunakan *Confusion Matrix*. Akurasi dari klasifikasi menggunakan CNN sederhana menghasilkan 80%, hasil model *transfer learning* VGG-16 mendapat akurasi sebesar 95%, Inception-V3 mendapat akurasi sebesar 78% dan ResNet-50 mendapat akurasi 78%.

IV. KESIMPULAN

Berdasarkan hasil dari percobaan proses klasifikasi penyakit daun tanaman kentang pada penelitian ini dapat diambil kesimpulan bahwa klasifikasi citra daun kentang dengan menggunakan arsitektur CNN yang sederhana menghasilkan performa model klasifikasi yang *overfitting*. Hasil percobaan klasifikasi menggunakan metode *transfer learning* antara model VGG-16, Inception-V3 dan ResNet-50 menghasilkan bahwa model VGG-16 memiliki hasil yang paling baik, dibuktikan dengan performa model yang stabil dan akurasi yang paling tinggi dengan jumlah 95%. Model *transfer learning* VGG-16 dapat digunakan untuk penelitian selanjutnya apabila data

yang digunakan sedikit, karena pada saat proses pengumpulan data tidak selalu para peneliti mendapatkan data yang ideal dan besar.

REFERENSI

- [1] A. N. Furrer, M. Chegeni, and M. G. Ferruzzi, "Impact of potato processing on nutrients, phytochemicals, and human health," *Crit. Rev. Food Sci. Nutr.*, vol. 58, no. 1, pp. 146–168, Jan. 2018, doi: 10.1080/10408398.2016.1139542.
- [2] K. A. Beals, "Potatoes , Nutrition and Health," *Am. J. Potato Res.*, vol. 96, pp. 102–110, 2019, doi: 10.1007/s12230-018-09705-4.
- [3] J. Chen, J. Chen, D. Zhang, Y. Sun, and Y. A. Nanekaran, "Using deep transfer learning for image-based plant disease identification," *Comput. Electron. Agric.*, vol. 173, no. March, p. 105393, 2020, doi: 10.1016/j.compag.2020.105393.
- [4] R. Yusianto, Marimin, Suprihatin, and H. Hardjomidjojo, "An Interpretive Structural Modeling (ISM) approach for Institutional Development in the Central Java Potato Agroindustry," *Proc. - 2019 Int. Semin. Appl. Technol. Inf. Commun. Ind. 4.0 Retrospect. Prospect. Challenges, iSemantic 2019*, no. 2018, pp. 282–287, 2019, doi: 10.1109/ISEMANTIC.2019.8884325.
- [5] S. Tafesse *et al.*, "Farmers' knowledge and practices of potato disease management in Ethiopia," *NJAS - Wageningen J. Life Sci.*, vol. 86–87, no. September 2017, pp. 25–38, 2018, doi: 10.1016/j.njas.2018.03.004.
- [6] I. K. Abuley and B. J. Nielsen, "Evaluation of models to control potato early blight (*Alternaria solani*) in Denmark," *Crop Prot.*, vol. 102, pp. 118–128, 2017, doi: 10.1016/j.cropro.2017.08.012.
- [7] B. Kumbar *et al.*, "Field application of *Bacillus subtilis* isolates for controlling late blight disease of potato caused by *Phytophthora infestans*," *Biocatal. Agric. Biotechnol.*, vol. 22, no. April, p. 101366, 2019, doi: 10.1016/j.bcab.2019.101366.
- [8] P. Patil, N. Yaligar, and S. . Meena, "Comparison of Performance of Classifiers - SVM, RF and ANN in Potato Blight Disease Detection Using Leaf Images," *IEEE Int. Conf. Comput. Intell. Comput. Res. ICCIC 2017*, pp. 1–5, 2017, doi: 10.1109/ICCIC.2017.8524301.
- [9] U. Suttapakti and A. Bunpeng, "Potato Leaf Disease Classification Based on Distinct Color and Texture Feature Extraction," *Proc. - 2019 19th Int. Symp. Commun. Inf. Technol. Isc. 2019*, no. Mcd, pp. 82–85, 2019, doi: 10.1109/ISCIT.2019.8905128.
- [10] M. A. Iqbal and K. H. Talukder, "Detection of Potato Disease Using Image Segmentation and Machine Learning," *2020 Int. Conf. Wirel. Commun. Signal Process. Networking, WiSPNET 2020*, pp. 43–47, 2020, doi: 10.1109/WiSPNET48689.2020.9198563.
- [11] F. S. Ni'mah, T. Sutojo, and D. R. I. M. Setiadi, "Identifikasi Tumbuhan Obat Herbal Berdasarkan Citra Daun Menggunakan Algoritma Gray Level Co-occurrence Matrix dan K-Nearest Neighbor," *J. Teknol. dan Sist. Komput.*, vol. 6, no. 2, pp. 51–56, 2018, doi: 10.14710/jtsiskom.6.2.2018.51-56.
- [12] P. U. Rakhmawati, Y. M. Pranoto, and E. Setyati, "Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur Dan Fitur Warna Menggunakan Support Vector Machine," *Semin. Nas. Teknol. dan Rekayasa 2018*, pp. 1–8, 2018.
- [13] T. T. Mim, M. H. Sheikh, R. A. Shampa, M. S. Reza, and M. S. Islam, "Leaves Diseases Detection of Tomato Using Image Processing," in *2019 8th International Conference System Modeling and Advancement in Research Trends (SMART)*, Nov. 2019, pp. 244–249, doi: 10.1109/SMART46866.2019.9117437.
- [14] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *J. Ilm. Geomatika-JIG*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [15] Y. D. Zhang *et al.*, "Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation," *Multimed. Tools Appl.*, vol. 78, no. 3, pp. 3613–3632, 2019, doi: 10.1007/s11042-017-5243-3.
- [16] N. Jmour, S. Zayen, and A. Abdelkrim, "Convolutional neural networks for image classification," *2018 Int. Conf. Adv. Syst. Electr. Technol. IC_ASET 2018*, pp. 397–402, 2018, doi: 10.1109/ASET.2018.8379889.
- [17] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," *J. Informatics Comput. Sci.*, vol. 01, no. 02, pp. 104–108, 2019, [Online]. Available: [jurnalmahasiswa.unesa.ac.id > article](http://jurnalmahasiswa.unesa.ac.id/article).
- [18] R. Sharma, A. Singh, and V. Sharma, "Potato Leaf Diseases Identification using CNN," *J. Emerg. Technol. Innov. Res.*, vol. 5, no. 12, pp. 519–527, 2018.
- [19] A. Lumini and L. Nanni, "Deep learning and transfer learning features for plankton classification," *Ecol. Inform.*, vol. 51, no. November 2018, pp. 33–43, 2019, doi: 10.1016/j.ecoinf.2019.02.007.

- [20] T. Kaur and T. K. Gandhi, "Automated brain image classification based on VGG-16 and transfer learning," *Proc. - 2019 Int. Conf. Inf. Technol. ICIT 2019*, pp. 94–98, 2019, doi: 10.1109/ICIT48102.2019.00023.
- [21] X. Xia, C. Xu, and B. Nan, "Inception-v3 for flower classification," *2017 2nd Int. Conf. Image, Vis. Comput. ICIVC 2017*, pp. 783–787, 2017, doi: 10.1109/ICIVC.2017.7984661.
- [22] Z. Zahisham, C. P. Lee, and K. M. Lim, "Food Recognition with ResNet-50," pp. 1–5, 2020, doi: 10.1109/iicaiet49801.2020.9257825.
- [23] B. Wu, Z. Liu, Z. Yuan, G. Sun, and C. Wu, "Reducing overfitting in deep convolutional neural networks using redundancy regularizer," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10614 LNCS, pp. 49–55, 2017, doi: 10.1007/978-3-319-68612-7_6.
- [24] T. O. Emmanuel, "PlantVillage Dataset," *Kaggle.com*, 2018. <https://www.kaggle.com/emmarex/plantdisease> (accessed Jul. 24, 2020).
- [25] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, 2009, doi: 10.1016/j.ipm.2009.03.002.
- [26] S. Ruuska, W. Hämäläinen, S. Kajava, M. Mughal, P. Matilainen, and J. Mononen, "Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle," *Behav. Processes*, vol. 148, pp. 56–62, Mar. 2018, doi: 10.1016/j.beproc.2018.01.004.