

Perbandingan Kinerja Model Ensembled Transfer Learning Pada Klasifikasi Penyakit Daun Tomat

Muhammad Islahfari Wahid¹⁾, Armin Lawi²⁾, dan A. Muh, Amil Siddik³⁾

^{1,2,3} Fakultas MIPA/Departemen Matematika, Universitas Hasanuddin

¹wahidmi18h@student.unhas.ac.id, ²armin@unhas.ac.id, ³amiliddik@unhas.ac.id

Abstrak

Tomat merupakan salah satu sayuran yang umum dikonsumsi di dunia. Produksi tomat di Indonesia sendiri sangat luar biasa, pada tahun 2021 produksi tomat mencapai 1.035.475 (ton). Dan konsumsi tomat di Indonesia mencapai 1.053.249 (ton), artinya tomat menjadi salah satu buah yang sangat dibutuhkan di Indonesia. Namun karena kebutuhan yang tinggi seringkali terjadi kenaikan harga yang signifikan pada tomat. Hal ini dikarenakan berbagai jenis penyakit yang menghambat produksi tanaman tomat. Oleh karena itu dibutuhkan sebuah metode yang dapat mengidentifikasi penyakit tanaman tomat dengan hasil yang optimal. Metode yang digunakan adalah Deep Learning dengan menggunakan algoritma Convolutional Neural Network (CNN) beserta arsitektur InceptionV3, Xception dan VGG16. Untuk meningkatkan performa model dapat digunakan metode Ensembled Stacking. Penelitian dilakukan dengan 700 data citra penyakit daun tomat yang terbagi menjadi 7 kelas. Dari tiga arsitektur yang digunakan, model Xception mendapatkan akurasi training sebesar 99% dan akurasi validation sebesar 95%. Untuk model InceptionV3 mendapatkan akurasi training sebesar 99% dan akurasi validation sebesar 91%. Dan untuk model VGG16 mendapatkan akurasi training sebesar 87% dan akurasi validation sebesar 90%. Selanjutnya digunakan metode Ensembled Stacking untuk meningkatkan performa model. Hasil dari metode ini lebih baik dibandingkan tiga model arsitektur sebelumnya dengan mendapatkan akurasi training sebesar 99% dan akurasi validation sebesar 99%.

Keywords: *Convolutional Neural Network (CNN), pengolahan citra, Ensemble, penyakit daun tomat.*

I. PENDAHULUAN

Tomat merupakan salah satu komoditas hortikultura yang sering menjadi sumber bahan makanan. Tomat sangat potensial dikembangkan dan bernilai jual tinggi. Tingginya permintaan pasar terhadap buah tomat, baik tomat segar maupun tomat olahan membutuhkan produktifitas yang tinggi pada sektor pertanian tomat [1]. Dari hasil proyeksi yang dilakukan oleh Pusat Data dan Informasi Pertanian Indonesia bahwa pada tahun 2021 produksi tomat akan mencapai 1.035.475 ton dan konsumsi tomat akan mencapai 1.053.249 ton.

Dalam hal ini jumlah konsumsi tomat lebih banyak daripada produksi tomat sehingga akan terjadi kekurangan stok produksi. Kenaikan harga tomat yang cukup signifikan akibat kekurangan stok produksi [2]. Hingga saat ini peningkatan produksi tomat masih terkendala oleh faktor penyakit tanaman [3]. Penyakit yang menyerang tanaman tomat merupakan ancaman yang dapat menghambat produksi tomat global dan berefek pada kerugian pasca panen yang signifikan [4]. Sangat penting bagi petani untuk mendeteksi penyakit pada tanaman lebih awal untuk mengontrol penyebaran penyakit [11]. Maka dari itu perlu untuk dapat mengidentifikasi jenis penyakit daun tomat dengan mudah.

Saat ini metode yang paling baik dalam pengenalan citra yaitu CNN. Metode ini memiliki beragam arsitektur yaitu VGG16, MobileNet, Xception, InceptionV3, dll. Selain itu untuk meningkatkan performa model agar lebih baik dalam mengenali citra dapat menggunakan metode

Ensemble. Karena itu penelitian ini berfokus tentang identifikasi citra penyakit daun tomat dengan menggunakan metode CNN serta meningkatkan performa model dengan menggunakan metode Ensemble.

II. KAJIAN LITERATUR

Penelitian dengan menggunakan data citra telah banyak digunakan dalam berbagai bidang. Salah satunya pada bidang pertanian, dalam bidang pertanian sudah banyak penelitian yang berhubungan dengan data citra seperti sistem untuk mendeteksi gangguan serangga, menentukan masa panen, dan sebagainya. Berikut beberapa penelitian mengenai image processing pada bidang pertanian.

Penelitian yang dilakukan oleh Felix, et al (2019), dengan judul Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun. Penelitian ini menggunakan 200 data citra yang terbagi dalam empat kelas. Peneliti melakukan transformasi data citra dari warna Red Green Blue (RGB) menjadi HSV, kemudian diubah menjadi Grayscale. Hasil dari penelitian ini didapatkan akurasi menggunakan algoritma CNN sebesar 97,5% dan SVM sebesar 95% [5].


Penelitian yang dilakukan Mendes dan Silva pada tahun 2018 menggunakan salah satu arsitektur CNN dan juga memanfaatkan metode transfer learning. Dataset yang digunakan terdiri dari dua belas jenis skin lesi dari dua dataset berbeda yaitu Atlas Dataset dan Edinburgh Dataset. Peneliti melakukan augmentasi pada data citra yang dimiliki untuk mendapatkan gambar yang memiliki

cahaya yang berbeda. Selanjutnya model dibuat dengan menggunakan arsitektur ResNet-152. Peneliti juga mengimplementasi transfer learning dengan menggunakan bobot yang telah dilatih menggunakan ImageNet. Hasil AUC yang didapatkan tiap kelas diatas 0.90. [6].

Penelitian dengan menggunakan metode ensemble pernah dilakukan oleh Yoga pada tahun 2022. Penelitian ini bertujuan untuk meningkatkan kinerja model single classifier pada dataset yang imbalance. Algoritma yang digunakan pada single classifier yaitu C4.5, K-NN, SVM, dan Random Forest. Dengan menggunakan metode ensemble stacking, peneliti mendapatkan hasil akurasi lebih baik dibandingkan single classifier. Pada dataset pertama model stacking mendapatkan akurasi sebesar 89% dan pada dataset kedua mendapatkan akurasi sebesar 96% [7].

A. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan pengembangan dari Multi-Layer Perceptron (MPL) yang dirancang untuk mengolah data dalam bentuk grid, salah satunya adalah citra dua dimensi. CNN digunakan untuk mengklasifikasikan data yang terlabel dengan menggunakan metode Supervised Learning. CNN sering digunakan untuk mengenali benda atau mendeteksi suatu objek.



Gambar 1. Convolutional Neural Network.

Pada gambar terlihat secara garis besar terdapat dua proses pada CNN. Proses pertama adalah Feature Extraction yang meliputi convolution dan pooling. Kemudian proses kedua yaitu Classification yang meliputi flatten, dan fully connected layer.

- i. Convolution Layer
Convolution Layer menggunakan filter untuk mengekstraksi sebuah objek. Filter ini berisi bobot yang digunakan untuk mendeteksi objek seperti tepi, kurva, atau warna. Output yang dihasilkan konvolusi adalah transformasi linear.
- ii. Pooling
Pooling merupakan metode yang bertujuan mengurangi ukuran feature map dari hasil proses konvolusi. Dalam pooling terdapat dua metode yaitu average pooling dan max pooling. Average pooling mengambil nilai rata-rata sedangkan max pooling mengambil nilai maksimal.
- iii. Activation Function
Rectification Linear Unit (ReLU) merupakan sebuah fungsi yang bertujuan mengenalkan non-linearitas dan meningkatkan representasi dari model. Jika nilai input adalah negatif maka dapat

dinyatakan outputnya adalah 0, sedangkan jika nilai inputnya positif maka outputnya adalah nilainya sendiri.


- iv. Flatten
Flatten merupakan proses paling akhir dari Feature Extraction. Flaten berfungsi mengubah dimensi output proses Convolution dan pooling menjadi satu dimensi.
- v. Fully Connected Layer
Fully connected layer biasanya berada pada layer paling akhir. Layer paling akhir digunakan untuk menentukan kelas, lapisan ini mendapatkan input dari proses sebelumnya untuk menentukan fitur mana yang paling berkorelasi dengan kelas tertentu.

B. Arsitektur CNN Transfer Learning

Terdapat beberapa arsitektur pada Convolutional Neural Network (CNN) untuk pengklasifikasian citra. Pada tahun 2012, arsitektur CNN AlexNet yang berhasil menjadi pemenang ImageNet Competition yaitu kompetisi untuk klasifikasi dan deteksi citra yang terdiri dari jutaan citra dengan puluhan ribu kelas [8].

Transfer learning adalah metode menggunakan jaringan saraf yang sudah dilatih sebelumnya lalu mengurangi jumlah parameter dengan cara mengambil beberapa bagian dari model yang sudah dilatih untuk digunakan dalam mengenali model baru [9]. Transfer learning melatih model dengan memanfaatkan ImageNet sebagai pengetahuan umum untuk model. Dalam transfer learning terdapat beberapa istilah seperti pre-trained dan fine tuning. Transfer learning nantinya akan melatih model dengan menggunakan data besar, inilah yang disebut pre-trained. Selain pre-trained, fine-tuning juga merupakan sebuah cara yang biasanya dipakai dalam melatih model. Model yang sudah dilakukan pre-trained akan dilatih lagi menggunakan data baru untuk kebutuhan lain. Dalam penelitian ini arsitektur yang digunakan adalah InceptionV3, Xception, dan VGG16.

Transfer learning: idea



Gambar 2. Transfer Learning.


- i. InceptionV3
InceptionV3 dibuat pada tahun 2015 dengan jumlah 42 layer. InceptionV3 memiliki tingkat error yang lebih rendah dibandingkan InceptionV2. Arsitektur InceptionV3 melakukan beberapa perbaikan seperti penggunaan label smoothing, konvolusi 7x7, dan classifier tambahan.

- ii. Xception
Xception merupakan arsitektur yang melibatkan *Depthwise Separable Convolutions*. Xception sebagai interpretasi modul *inception* yang bertujuan sebagai langkah perantara di antara konvolusi reguler dan operasi konvolusi. Arsitektur Xception memiliki 71 layer.
- iii. VGG16
Arsitektur VGG16 merupakan versi pengembangan dari AlexNet. Ketika model diuji menggunakan dataset ImageNet, menunjukkan akurasi tes sebesar 92.7%. VGG16 menggunakan 16 layer yang terdiri dari 13 layer *convolution* dan 3 layer *fully connected*

C. Ensemble Learning

Ensemble learning merupakan metode yang mencari model terbaik dengan cara menggabungkan beberapa model. Model dilatih dengan sendiri-sendiri kemudian mengkombinasikan model tersebut. Teknik ini lebih tahan terhadap noise dibandingkan dengan penggunaan classifier tunggal. Metode ini menggunakan pendekatan “divide and conquer” di mana masalah yang rumit diuraikan menjadi beberapa sub-masalah [10].

Salah satu metode ensemble yaitu stacking. Teknik stacking bekerja dengan cara menggabungkan beberapa model yang disebut weak-learner, yang kemudian digabungkan menggunakan model yang disebut meta-learner. Stacking terdiri dari dua level yaitu base learner sebagai level-0 dan stacking model learner sebagai level-1 atau meta learner.



Gambar 3. Ensemble Learning

D. Evaluasi Kinerja Model

Evaluasi kinerja model merupakan yang terpenting dalam menentukan suatu model bagus atau tidak. Pada kasus klasifikasi, evaluasi kinerja yang digunakan berupa *Confusion matrix*, *precision*, *recall*, *accuracy* dan *F1-score*. Terdapat beberapa pengukuran kinerja model yang digunakan dalam penelitian ini.

- i. Confusion Matrix
Confusion matrix merupakan pengukuran performa yang digunakan pada masalah klasifikasi, confusion matrix dapat berupa keluaran visualisasi yang menunjukkan hasil prediksi dari model yang benar maupun salah.

Tabel 1. Confusion Matrix

		Aktual		
		Kelas 1	Kelas 2	Kelas 3
Prediksi	Kelas 1	T ₁₁	F ₁₂	F ₁₃
	Kelas 2	F ₂₁	T ₂₂	F ₂₃
	Kelas 3	F ₃₁	F ₃₁	T ₃₃

- ii. Accuracy
Accuracy Merupakan rasio prediksi Benar (positif dan negatif) dengan keseluruhan data. Biasanya akurasi suatu model ditentukan dalam bentuk persen.

$$Accuracy = \frac{\sum_{i=1}^c T_i}{N} \quad (1)$$

- iii. Precision
Precision merupakan rasio prediksi benar positif kelas i dibandingkan dengan keseluruhan hasil yang terprediksi positif kelas i.

$$Precision_i = \frac{T_i}{T_i + \sum_{j=1}^c F_{ij}} \quad (2)$$

- iv. Recall
Recall merupakan rasio prediksi benar positif kelas i dibandingkan dengan keseluruhan data yang benar positif kelas i. Berikut rumus recall yang digunakan.

$$Recall_i = \frac{T_i}{T_i + \sum_{j=1}^c F_{ij}} \quad (3)$$

- v. F1-score
F1-score merupakan perbandingan rata-rata presisi dan recall.

$$F1-Score = \frac{2 \times Recall_i \times Precision_i}{Recall_i + Precision_i} \quad (4)$$

III. METODE PENELITIAN

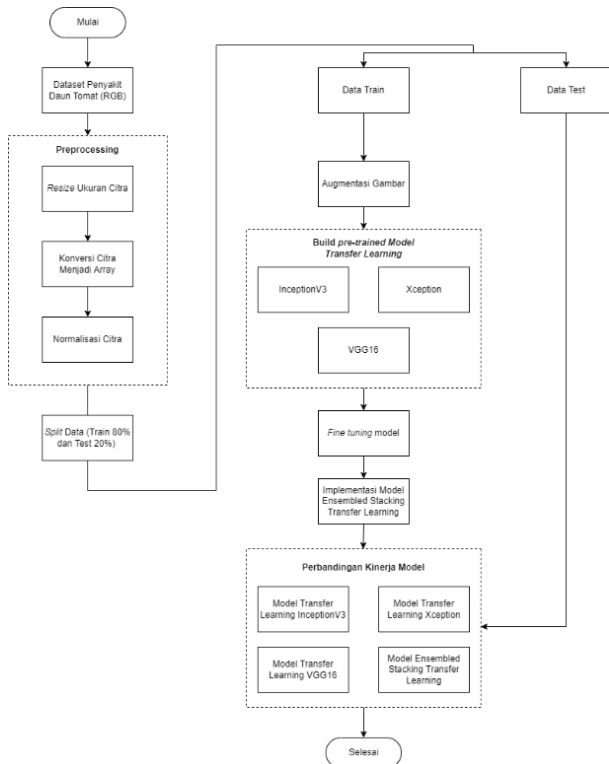
A. Dataset

Data yang digunakan pada penelitian ini yaitu berupa data citra penyakit daun tomat. Dataset tersebut diperoleh dari repository kaggle yaitu Tomato Leaf Disease Detection. Dataset terdiri dari 7 kelas yaitu Tomato late blight, Tomato spider mates, Tomato leaf mold, Tomato target spot, Tomato healthy, Tomato early blight, dan Tomato bacterial spot.

Tabel 2. Dataset Penyakit Daun Tomat

No	Kelas	Jumlah
1	Tomato late blight	100
2	Tomato spider mates	100
3	Tomato leaf mold	100
4	Tomato target spot	100
5	Tomato healthy	100
6	Tomato early blight	100
7	Tomato bacterial spot	100

B. Alur Penelitian



Gambar 4. Alur Penelitian.

- i. **Preprocessing**
Langkah awal pada penelitian ini adalah preprocessing, setelah data citra di import ke drive. Selanjutnya data citra akan dipilih sebanyak 100 data citra tiap kelas. Kemudian dilakukan resize pada data citra menjadi ukuran 299x299. Ini dilakukan agar jumlah pixel yang diolah tiap model itu sama. Setelah itu data citra dikonversi menjadi array dengan rentang 0-255. Hasil konversi array akan dilakukan normalisasi agar rentang citra menjadi 0-1.
- ii. **Split Data**
Langkah selanjutnya adalah pembagian data, data akan dibagi menjadi data training dan data testing. Dari total 700 data citra, akan dibagi sebanyak 80% data training dan sebanyak 20% data testing.
- iii. **Build Model Transfer Learning**
Sebelum data training digunakan untuk model, data tersebut dilakukan augmentasi. Pada proses augmentasi, data training diubah menjadi satu atau banyak data baru. Model base learner yang dibangun menggunakan arsitektur InceptionV3, Xception, dan VGG16 merupakan model pre-trained. Setelah itu model memasuki proses fine tuning.
- iv. **Implementasi Model Ensemble Transfer Learning**
Pada tahap ini, setelah model dari tiap arsitektur sudah dilatih. Selanjutnya output dari hasil pelatihan akan digabungkan menggunakan fungsi concatenate. Kemudian model meta-learner akan


dibangun menggunakan Multilayer perceptron (MLP).

- v. **Evaluasi Kinerja Model**
Tahap terakhir, tiap model akan dievaluasi untuk melihat kinerja terbaik. Pada penelitian ini evaluasi kinerja model yang digunakan adalah confusion matrix, precision, recall, dan accuracy.

IV. HASIL DAN PEMBAHASAN

A. Preprocessing

Tahap pertama pada preprocessing adalah mengubah ukuran data citra agar menyesuaikan pada tiap model arsitektur yang dibuat. Pada penelitian ini semua data citra diubah menjadi ukuran 299x299 pixel. Arsitektur CNN yang digunakan akan memiliki input size 299x299. Proses selanjutnya adalah mengkonversi data citra menjadi array. Tahap ini akan menghasilkan nilai setiap pixel yang berupa angka dari skala 0-255. Proses terakhir adalah normalisasi/pengubahan skala nilai citra menjadi 0-1.




Gambar 5. Hasil Preprocessing

B. Split Data

Jumlah data citra adalah 700. Selanjutnya data citra dilakukan pembagian data training dan data testing. Data training sebanyak 80% dan data testing sebanyak 20% dari jumlah data, sehingga data training berjumlah 560 data citra dan data testing berjumlah 140 data citra.

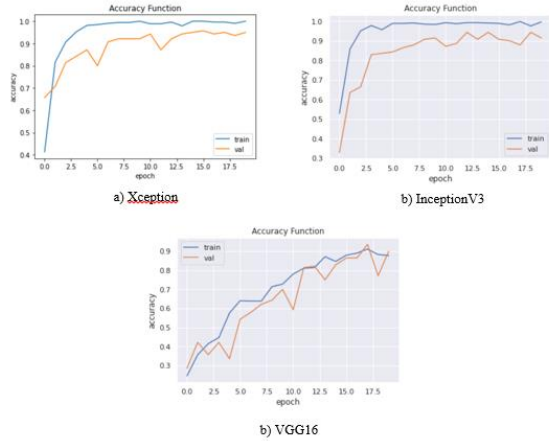
C. Augmentasi Data

Pada proses ini setiap citra akan dimodifikasi sehingga citra asli akan diubah bentuk maupun posisinya dengan begitu data citra yang digunakan untuk training akan lebih beragam.




Gambar 6. Augmentasi Data Citra.

D. Kurva Akurasi InceptionV3, Xception, dan VGG16



Gambar 7. Kurva Akurasi Pada Model
Dapat dilihat pada gambar, akurasi dari model Xception dan Inception mengalami kenaikan signifikan di awal epoch. Sedangkan pada model VGG16 akurasinya naik namun tidak signifikan, dimana terlihat kurva bergelombang.

E. Confusion Matrix InceptionV3, Xception, dan VGG16



Gambar 8. Confusion Matrix

Pada gambar terlihat jumlah kesalahan prediksi terendah pada model Xception yaitu 7 kesalahan klasifikasi. Sedangkan pada model InceptionV3 mendapatkan 12 kesalahan klasifikasi dan model VGG16 mendapatkan 14 kesalahan klasifikasi.

F. Precision, Recall, dan F1-score

Kelas	Pesisi	Recall	F1-Score
Tomato late blight	0.95	1.00	0.98
Tomato spider mates	0.91	1.00	0.95
Tomato leaf mold	1.00	0.85	0.92
Tomato target spot	0.86	0.95	0.90
Tomato healthy	1.00	0.95	0.97
Tomato early blight	0.95	0.90	0.92
Tomato bacterial spot	1.00	1.00	1.00

a) Xception

Kelas	Pesisi	Recall	F1-Score
Tomato late blight	0.95	1.00	0.98
Tomato spider mates	0.77	1.00	0.87
Tomato leaf mold	1.00	0.95	0.97
Tomato target spot	0.82	0.90	0.86
Tomato healthy	1.00	0.85	0.92
Tomato early blight	1.00	0.75	0.86
Tomato bacterial spot	0.95	0.95	0.95

b) InceptionV3

Kelas	Pesisi	Recall	F1-Score
Tomato late blight	0.86	0.90	0.88
Tomato spider mates	0.89	0.80	0.84
Tomato leaf mold	1.00	0.80	0.89
Tomato target spot	0.73	0.95	0.83
Tomato healthy	0.90	0.95	0.93
Tomato early blight	1.00	0.90	0.95
Tomato bacterial spot	1.00	1.00	1.00

b) VGG16


Gambar 9. Precision, Recall, dan F1-score

Pada gambar dapat dilihat arsitektur Xception merupakan yang terbaik karena sebagian besar mendapatkan nilai di atas 0.90. Sedangkan arsitektur InceptionV3 dan VGG16 sebagian besar mendapatkan nilai di bawah 0.90 bahkan ada nilai di bawah 0.80.

G. Ensemble Stacking Transfer Learning


Pada arsitektur model ensemble stacking terdapat tiga cabang model sesuai dengan arsitektur yang digunakan. Output bobot dari tiap model akan digabungkan menggunakan layer concatenate. Kemudian ada dense layer sebagai layer paling akhir pada model ensemble stacking.

i. Kurva Akurasi



Gambar 10. Kurva Akurasi Ensemble Model
Dapat dilihat bahwa model Ensembled Transfer Learning memiliki kurva akurasi yang lebih stabil dibandingkan tiga arsitektur sebelumnya.

ii. Confusion Matrix



Gambar 11. Confusion Matrix Ensemble Model

Hanya 1 kesalahan prediksi yang didapatkan dari model Ensembled Transfer Learning, dimana hasil ini sangat jauh berbeda dari tiga arsitektur sebelumnya.

iii. Precision, Recall, dan F1-score

Kelas	Pesisi	Recall	F1-Score
Tomato late blight	1.00	1.00	1.00
Tomato spider mates	0.95	1.00	0.98
Tomato leaf mold	1.00	1.00	1.00
Tomato target spot	1.00	1.00	1.00
Tomato healthy	1.00	0.95	0.97
Tomato early blight	1.00	1.00	1.00
Tomato bacterial spot	1.00	1.00	1.00

Gambar 12. Precision, Recall, dan F1-score Ensemble Model

Hasil yang didapatkan dari model Ensemble Transfer Learning jauh lebih baik

dibandingkan tiga model sebelumnya, dimana nilai precision, recall, dan f1-score mendapatkan nilai 1.0 hampir semua kelas.

E. KESIMPULAN

Berdasarkan hasil dari penelitian yang dilakukan, maka dapat ditarik kesimpulan sebagai berikut:

- i. Dari hasil training dan validation menggunakan model ensembled transfer learning CNN pada citra penyakit daun tomat dengan jumlah 700 data citra menghasilkan kinerja terbaik pada epoch ke-20 dengan akurasi training sebesar 99% dan akurasi validation sebesar 99%.
- ii. Untuk precision, recall, dan f1-score pada model ensembled transfer learning CNN memiliki nilai yang sangat baik, dimana nilai yang didapatkan 1.0 pada semua kelas. Berdasarkan evaluasi kinerja model terbukti metode ensemble stacking dapat meningkatkan kinerja model.

UCAPAN TERIMA KASIH

Semua pihak yang telah memberikan bantuan kepada penulis baik berupa materi dan non materi yang tidak dapat penulis sebutkan satu persatu, terima kasih untuk bantuan dan dukungannya.

REFERENSI

- [1] Adhikari, P., Oh, Y., & Panthee, D. R. (2017). Current status of early blight resistance in tomato: An update. *International Journal of Molecular Sciences*, 18(10). doi: 10.3390/ijms18102019.
- [2] Sita, B. R., & Hadi, S. (2016). Produktivitas Dan Faktor-Faktor Yang Berpengaruh Terhadap Produksi Usahatani Tomat (*Solanum Lycopersicum Mill*) Di Kabupaten Jember. *JSEP*, 9(3).
- [3] Astiningrum, M., Arhandi, P. P., & Ariditya, N. A. (2019). Identifikasi Penyakit pada Daun Tomat Berdasarkan Fitur Warna dan Tekstur. *Jurusan Teknologi Informasi Politeknik Negeri Malang*, pp. 1-4.
- [4] Ali, M. M., Bachik, N. A., Muhadi, N. A., & Yusof, T. N. T. (2019). Non-destructive techniques of detecting plant diseases: A review. *Physiological and Molecular Plant Pathology*. Elsevier Ltd, 108, p. 101426. doi: 10.1016/j.pmpp.2019.101426.
- [5] Felix, Faisal, S., Butarbutar, T. F. M., & Sirait, P. (2019). Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun. *Jurnal SIFO Mikroskil*, 20(2).
- [6] Mendes, D. B., & Silva, N. C. (2018). Skin Lesions Classification Using Convolutional Neural Networks in Clinical Images. <https://arxiv.org/pdf/1812.02316>
- [7] Prityanto, Y., Sidauruk, A., & Nurmasani, A. (2022). Klasifikasi Penyakit Diabetes Pada Imbalanced Class Dataset Menggunakan Algoritme Stacking. *Jurnal Media Informatika Budidarma*, 6(1).
- [8] Setiawan, W. (2019). Perbandingan Arsitektur Convolutional Neural Network Untuk Klasifikasi Fundus. *Jurnal SimanteC*, 7(2).
- [9] Abas, M. A. H., Ismail, N., Yassin, A. I. M., & Taib, M. N. (2018). VGG16 for Plant Image Classification with Transfer Learning and Data Augmentation. *International Journal of Engineering & Technology*, 7(4).
- [10] Sidik, D. D. (2019). Penggunaan Stacking Classifier Untuk Prediksi Curah Hujan. *IT FOR SOCIETY*, 4(1).
- [11] Martinelli, F., dkk. (2015). Advanced methods of plant disease detection. A review. *Agronomy for Sustainable Development*, 35(1), pp. 1–25. doi: 10.1007/s13593-014-0246-1.