

# KLASIFIKASI PENYAKIT CITRA DAUN TANAMAN TOMAT DENGAN ENSEMBLE CONVOLUTIONAL NEURAL NETWORK

Armin Lawi<sup>1</sup>, Naili Suri Intizhami<sup>2</sup>, Rio Mukhtarom<sup>3</sup>, Supri Amir<sup>4</sup>

<sup>1,2</sup> Program Studi Ilmu Komputer, Institut Teknologi Bacharuddin Jusuf Habibie, Parepare, Indonesia

<sup>1,3,4</sup> Program Studi Ilmu Komputer, Universitas Hasanuddin, Makassar, Indonesia

armin@ith.ac.id<sup>1</sup>, naili.suri@ith.ac.id<sup>2</sup>, riomukhtarom10@gmail.com<sup>3</sup>, supriamir@unhas.ac.id<sup>4</sup>

## Abstrak

Tomat merupakan tanaman yang dapat tumbuh di hampir semua tanah yang gembur. Petani maupun tukang kebun sering menanam tomat baik untuk mereka konsumsi sendiri ataupun untuk dijual. Namun petani dan tukang kebun terkadang tidak bisa mendapatkan informasi yang tepat tentang pertumbuhan tanaman tomat sehingga muncul masalah seperti tomat yang busuk, tidak berbuah, muncul bercak coklat dan hitam, dan masih banyak lagi. Salah satu cara untuk mengatasi hal tersebut dengan melakukan klasifikasi penyakit pada daun tomat. Daun tomat menjadi salah satu faktor yang digunakan untuk melihat apakah tanaman tomat itu baik atau tidak. Penelitian ini akan menggunakan data gambar daun tomat yang sakit dan metode CNN sebagai metode klasifikasi citra. Penelitian ini akan berfokus pada metode *ensemble* CNN untuk mendapatkan hasil klasifikasi daun tomat sakit yang lebih baik daripada satu model CNN saja. Untuk perbandingannya, penelitian ini menggunakan 6 model CNN. Hasilnya, *Ensemble* CNN mendapatkan nilai akurasi sekitar 90.83% dengan rata-rata nilai *precision* dan *recall* diatas 0.8 hingga 1.0. Hasil keseluruhannya menunjukkan bahwa metode *ensemble* CNN secara umum lebih baik daripada satu model CNN saja.

**Keywords:** *Tomato, Tomato Leaf Disease, Convolutional Neural Network, Ensemble Learning, Ensemble CNN*

## I. PENDAHULUAN

Tomat (nama biologis: *Solanum lycopersicum*) merupakan tanaman yang dapat tumbuh di hampir semua tanah yang gembur baik dataran tinggi, dataran medium dan dataran rendah [1]. Sembilan dari 10 petani seringkali menanam tomat di ladang mereka. Bahkan banyak juga tukang kebun yang menanam tomat di kebun mereka sendiri agar dapat menggunakan tomat segar untuk di dapur mereka sehingga mendapatkan rasa makanan yang lebih enak dan sehat. Namun, baik petani dan tukang kebun terkadang tidak bisa mendapatkan informasi yang tepat tentang pertumbuhan tanaman [2]. Pada tanaman tomat sendiri, beberapa masalah yang sering muncul seperti, tanaman tomat yang tidak berbuah atau tomat yang terlihat jelek dan tomat yang memiliki bintik-bintik hitam penuh penyakit.

Pada tanaman tomat, identifikasi penyakit tanaman tomat dapat dimulai dari mendiagnosa bagian tanaman yang terkena infeksi misalnya daun, kemudian melihat perbedaannya seperti pada daun tomat ada bercak coklat atau hitam, lubang pada buah tomatnya dan kerusakan pada tomat karena hewan [3]. Hal ini terjadi karena kelembaban tanah dan suhu yang tinggi sehingga mendukung perkembangan penyakit, misalnya penyakit yang diakibatkan bakteri dan menyerang daun tanaman tomat dan membuatnya berubah warna menjadi coklat bahkan hitam. Akibat daun yang terkena bakteri, maka menghasilkan tomat yang sakit dan tidak baik untuk dikonsumsi [4]. Namun, memeriksa setiap daun pada tanaman tomat sangatlah menyita waktu dan tenaga dari petani ataupun tukang kebun. Saat ini deteksi penyakit tanaman telah dilakukan secara otomatis sebagai

pemantauan terhadap lahan yang luas untuk memudahkan para petani dan tukang kebun.

Berdasarkan hal tersebut metode pendeteksian penyakit pada tanaman tomat yang cepat dan tepat adalah dengan menggunakan metode klasifikasi dan menggunakan media citra. Pendekatan yang sering digunakan untuk melakukan klasifikasi untuk media citra ialah pendekatan Artificial Neural Network (ANN) dan Deep Learning. Artificial Neural Network (ANN) adalah proses komputasi yang terinspirasi pada cara kerja sistem saraf bekerja (seperti otak manusia). Salah satu algoritma deep feedforward dari metode Artificial Neural Network yang banyak diterapkan pada analisis citra adalah Convolutional Neural Networks atau biasa disingkat CNN [5].

Metode *ensemble learning* merupakan metode yang menggabungkan beberapa metode klasifikasi untuk mendapatkan output dengan akurasi yang lebih tinggi daripada hanya dengan menggunakan satu metode saja [6]. Metode *ensemble* CNN pada penelitian ini akan menggabungkan 6 model CNN untuk meningkatkan akurasi klasifikasi penyakit pada tanaman tomat dengan menggunakan data citra daun tanaman tomat. Diharapkan dengan metode CNN yang memiliki akurasi tinggi dikombinasikan dengan metode *ensemble learning* diharapkan dapat menghasilkan model yang sangat baik. Akurasi model dapat semakin meningkat serta error rate semakin berkurang.

## II. KAJIAN LITERATUR

Penyakit tanaman yang banyak dan sulit dikenali berakibat pada tingkat produktivitas bidang pertanian. Hal ini yang menjadi alasan utama V. Singh dan A. Misra [7] melakukan penelitian terkait pendeteksian penyakit pada

tanaman. Dengan menggunakan metode SVM dan media citra sebagai data. Penelitian ini mendapatkan akurasi klasifikasi mencapai 95,71%.

Penggunaan *machine learning* seperti *deep neural network* pada data pertanian mendapat perhatian besar dalam beberapa tahun terakhir. Salah satu masalah dalam bidang pertanian yaitu klasifikasi otomatis terhadap spesies tanaman berdasarkan tipenya. Klasifikasi tersebut berakibat pada pemberian pestisida, pemupukan, dan pemanenan pada spesies yang berbeda. Penelitian ini menggunakan CNN dan data citra untuk mengklasifikasikan tipe tanaman. Penelitian ini menghasilkan akurasi hingga 97,47% menggunakan CNN [8].

S. Vetal dan R. Khule [9] melakukan penelitian untuk mendeteksi penyakit pada tanaman tomat. Untuk mendeteksi penyakit, penelitian ini berfokus pada identifikasi pada daun tanaman tomat. Ada empat penyakit tanaman tomat yang diidentifikasi menggunakan image segmentation dan multi class SVM. Akurasi yang dihasilkan mencapai 93,75%.

Rangarajan [10] dalam penelitiannya mengusulkan metode deteksi penyakit pada tanaman tomat dengan cepat. Penelitiannya menggunakan data citra daun tomat tidak sehat dengan 6 jenis penyakit dan data citra daun tomat yang sehat. Data citra daun tomat diolah menggunakan dua arsitektur CNN, yaitu AlexNet dan VGG16Net. Sebanyak 13.262 citra diolah hingga menghasilkan akurasi 97,29% untuk VGG16Net dan 97,49% untuk AlexNet.

Wei Chen [11] dalam penelitiannya membuat model untuk mengklasifikasikan lima jenis kendaraan yang berbeda menggunakan algoritma adaboost dan deep convolutional neural network (CNN). Pada saat train data, dilakukan ekstraksi fitur menggunakan CNN. Hasil ekstraksi fiturnya diklasifikasi menggunakan beberapa model SVM. Kemudian dilakukan metode ensemble dengan menggunakan algoritma adaboost untuk menghasilkan model baru. Hasil uji coba dari model yang dibuat menghasilkan akurasi yang tinggi mencapai 99,50% pada data test, serta hanya membutuhkan 28 ms untuk mengidentifikasi suatu citra kendaraan. Performa dari model ini secara signifikan lebih baik dibanding algoritma tradisional seperti SIGT-SVM, HOG-SVM dan SURF-SVM. Bahkan ekstraksi fitur menggunakan CNN dapat mengurangi parameter pembelajaran sebelum training dengan menggunakan beberapa model SVM.

### III. METODE PENELITIAN

Terdapat empat sub bagian dalam menjelaskan metode penelitian ini yaitu dataset yang digunakan, praproses dataset, proses training, dan evaluasi performa.

#### A. Dataset

Data yang digunakan pada penelitian ini adalah data citra dari “*Plant Village Dataset*” yang diunduh dari <https://www.kaggle.com/datasets/emmarex/plantdisease>. Data citra berada dalam model warna RGB yang terdiri dari 6 kelas yaitu, *Bacterial Spot*, *Early Blight*, *Late Blight*, *Leaf*

*Mold*, *Septoria Leaf Spot*, *Yellow Leaf Curl Virus*. Jumlah data citra yang digunakan untuk 6 kelas adalah 1200 gambar.

#### A. Praproses dataset

Dataset yang digunakan merupakan data mentah sehingga diperlukan praproses untuk terlebih dahulu. Terdapat 3 proses yang akan dilakukan pada tahap ini, yaitu:

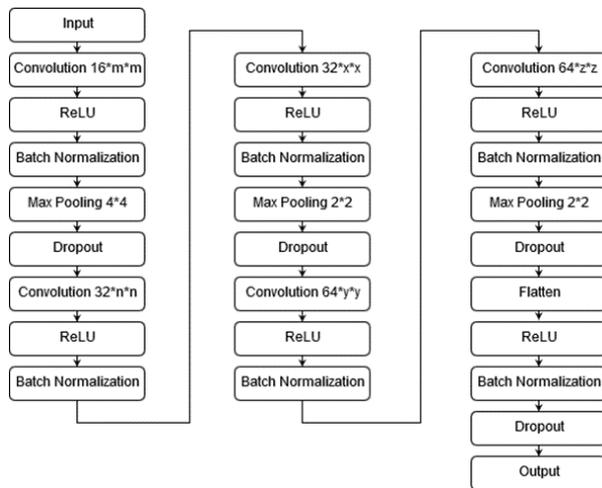
1. Mengubah Ukuran Gambar  
Data citra diubah ukurannya agar menyesuaikan dengan model CNN yang akan digunakan. Pada penelitian ini semua gambar diubah menjadi 256×256 piksel.
2. Normalisasi Data  
Mengubah citra menjadi matriks. Representasi citra dalam bentuk matriks akan menghasilkan nilai untuk setiap piksel dari citra yang mewakili warna pada piksel dengan skala 0-255. Skala ini kemudian diubah menjadi skala 0-1.
3. Pisahkan Data *Train* dan *Test*  
Data citra yang digunakan sebanyak 1200 gambar. Data citra ini kemudian dipisahkan menjadi 20% atau sebanyak 240 gambar untuk data *test* dan 80% atau sebanyak 960 untuk data *train*. Kemudian data *train* dibagi lagi menjadi data validasi dan data *train*, masing-masing sebanyak 20% dan 80%. Distribusi data citra pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Distribusi Data Citra

Kelompok Data	Jumlah Data
<i>Train</i>	768
Validasi	192
<i>Test</i>	240

#### B. Proses training

Data citra penyakit pada daun tomat diaplikasikan pada berbagai model CNN yang digunakan. Untuk setiap model CNN memiliki arsitektur yang sama yaitu terdiri dari, 5 lapisan konvolusi, 3 lapisan *pooling*, dan 3 lapisan *full connected*. Arsitektur CNN ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur CNN yang digunakan

Perbedaan untuk setiap model CNN yang digunakan terdapat pada ukuran lapisan konvolusi yang dapat dilihat pada Tabel 2.

Tabel 2. Lapisan konvolusi pada setiap model CNN

Model CNN	Konvolusi 1 Conv16(MxM)	Konvolusi 2 Conv32(NxN)	Konvolusi 3 Conv32(OxO)	Konvolusi 4 Conv64(PxP)	Konvolusi 5 Conv64(QxQ)
CNN 1	3 x 3	3 x 3	3 x 3	3 x 3	3 x 3
CNN 2	5 x 5	5 x 5	5 x 5	5 x 5	5 x 5
CNN 3	7 x 7	7 x 7	7 x 7	7 x 7	7 x 7
CNN 4	3 x 3	5 x 5	5 x 5	7 x 7	7 x 7
CNN 5	3 x 3	3 x 3	3 x 3	5 x 5	5 x 5
CNN 6	7 x 7	5 x 5	5 x 5	3 x 3	3 x 3

### C. Evaluasi Model

Model yang dihasilkan dari proses *training* akan dievaluasi dengan menggunakan *confusion matrix* [12], akurasi, *precision*, *recall*.

Tabel 3. *Confusion Matrix*

	Classes						
		BS	EB	LB	LM	LS	LC
Predicted Classes	BS	T <sub>BS</sub>	F <sub>BS EB</sub>	F <sub>BS LB</sub>	F <sub>BS LM</sub>	F <sub>BS LS</sub>	F <sub>BS LC</sub>
	EB	F <sub>EB BS</sub>	T <sub>EB</sub>	F <sub>EB LB</sub>	F <sub>EB LM</sub>	F <sub>EB LS</sub>	F <sub>EB LC</sub>
	LB	F <sub>LB BS</sub>	F <sub>LB EB</sub>	T <sub>LB</sub>	F <sub>LB LM</sub>	F <sub>LB LS</sub>	F <sub>LB LC</sub>
	LM	F <sub>LM BS</sub>	F <sub>LM EB</sub>	F <sub>LM LB</sub>	T <sub>LM</sub>	F <sub>LM LS</sub>	F <sub>LM LC</sub>
	LS	F <sub>LS BS</sub>	F <sub>LS EB</sub>	F <sub>LS LB</sub>	F <sub>LS LM</sub>	T <sub>LS</sub>	F <sub>LS LC</sub>
	LC	F <sub>LC BS</sub>	F <sub>LC EB</sub>	F <sub>LC LB</sub>	F <sub>LC LM</sub>	F <sub>LC LS</sub>	T <sub>LC</sub>

Tabel 3,  $T_x$  menyatakan jumlah data yang diprediksi benar sama dengan kelas sebenarnya  $x$ . Kemudian,  $F_{x|y}$  menyatakan bahwa jumlah data yang diprediksi salah di  $x$  padahal seharusnya di kelas  $y$ . Berdasarkan nilai-nilai pada Tabel 3, peneliti dapat mengevaluasi kinerja dari model yang digunakan.

$$Precision_x = \frac{T_x}{T_x + \sum_y F_{x|y}} \quad (1)$$

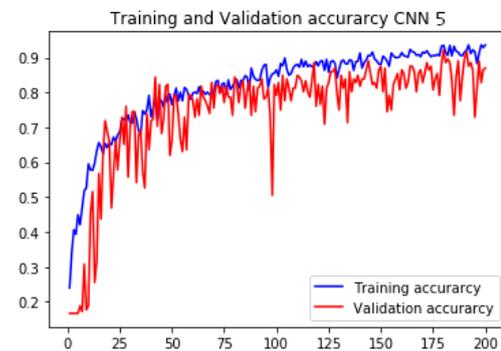
$$Recall_x = \frac{T_x}{T_x + \sum_y F_{y|x}} = \frac{T_x}{N_x} \quad (2)$$

$$Accuracy = \frac{\sum_x T_x}{\sum_x T_x + \sum_x \sum_y F_{y|x}} = \frac{\sum_x T_x}{N} \quad (3)$$

## IV. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian secara detail. Hasil penelitian dapat dilengkapi dengan tabel, grafik, gambar, atau diagram. Bagian pembahasan memaparkan hasil pengolahan data, menambahkan analisa secara logis, serta mengaitkan dengan sumber referensi yang relevan.

Data *train* dan validasi dilakukan *training* dengan menggunakan 6 model CNN yang telah dijelaskan pada II.C. setelah dilakukan *training* untuk 6 model CNN yang digunakan memiliki hasil yang berbeda. Namun, berdasarkan hasil *training* dari 6 model CNN, CNN 5 menjadi model CNN yang memiliki nilai akurasi yang paling baik, yaitu, 0.93 pada *epoch* 200 yang ditunjukkan pada Gambar 2.



Gambar 2. Grafik perubahan akurasi terhadap jumlah *epoch* pada data *train* dan validasi

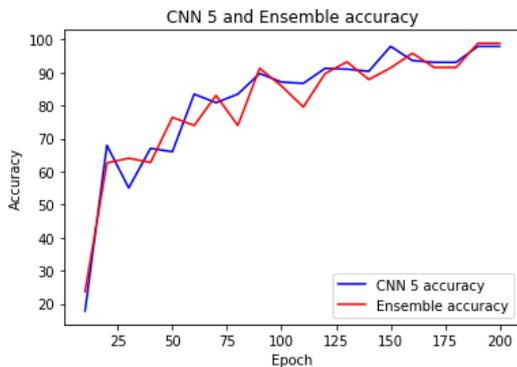
Setelah itu, dilakukan metode *ensemble learning* menggunakan 6 model CNN. Metode *ensemble* yang digunakan adalah metode *adaboost* [12]. Masing-masing model CNN melakukan prediksi terhadap data *train*. Kemudian hasil masing-masing model dikalikan dengan bobot *adaboost* yang ditunjukkan pada Tabel 4. Setelah itu, dilakukan *voting* untuk melihat hasil *ensemble* CNN.

Tabel 4. *Confusion Matrix*

Model	Bobot
CNN 1	0.284
CNN 2	0.081
CNN 3	0.142
CNN 4	0.260
CNN 5	0.083
CNN 6	0.148

Dengan menggunakan data yang sama. Hasil perbandingan antara model CNN dan metode *ensemble* ditunjukkan pada Gambar 3. Untuk model CNN yang dibandingkan adalah CNN 5 karena diproses sebelumnya,

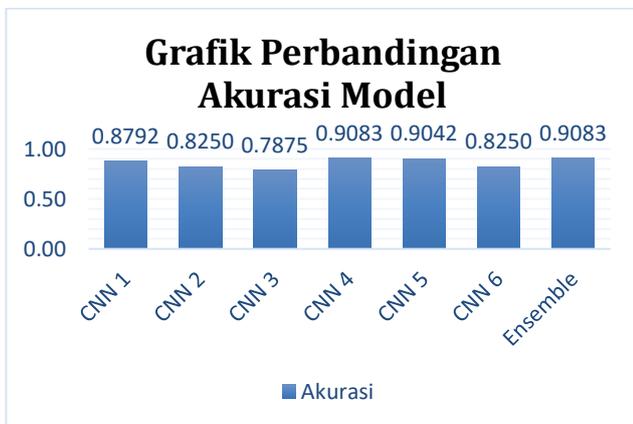
CNN 5 mendapatkan hasil yang lebih baik diantara 6 model CNN lainnya.



Gambar 3. Grafik perbandingan akurasi CNN 5 dengan *ensemble* CNN.

Terlihat bahwa dengan menggunakan metode *ensemble*, hasil akurasi yang didapatkan lebih baik daripada hanya menggunakan satu model CNN saja.

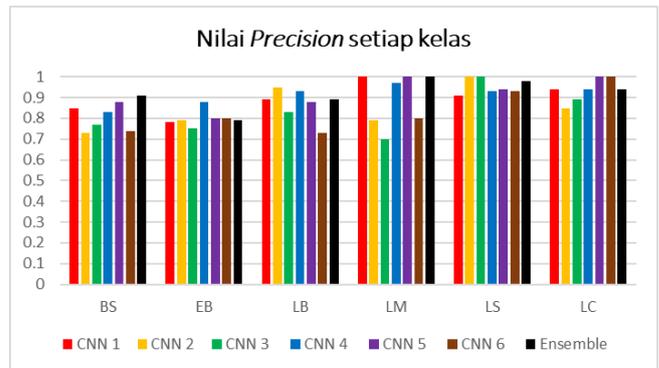
Setelah itu dilakukan evaluasi model hasil training dengan menggunakan data *test*. Hasil akurasi ditunjukkan pada Gambar 4.



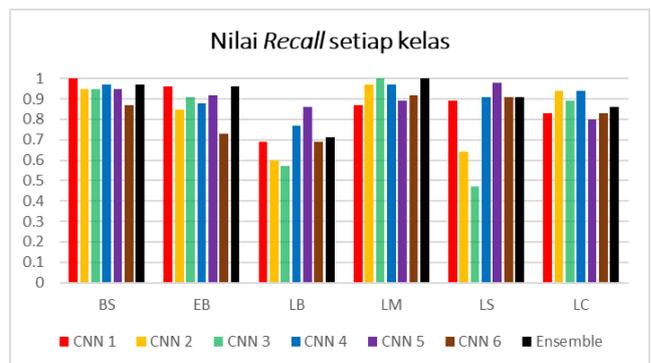
Gambar 4. Perbandingan akurasi model hasil training menggunakan data *test*.

Gambar 4 menunjukkan bahwa semua model CNN menghasilkan akurasi yang cukup baik. Namun, metode *ensemble* CNN ternyata masih bisa lebih baik daripada satu model CNN saja. Ini dibuktikan dengan hanya model CNN 4 saja yang juga mendapatkan skor akurasi sama baiknya dengan *ensemble* CNN.

Kemudian untuk hasil *precision* dan *recall* masing-masing ditunjukkan pada Gambar 5 dan 6 berturut-turut.



Gambar 5. Hasil *precision* untuk setiap kelas dengan menggunakan 6 model CNN dan *ensemble* CNN.



Gambar 6. Hasil *recall* untuk setiap kelas dengan menggunakan 6 model CNN dan *ensemble* CNN.

Dari Gambar 5 dan 6, terlihat bahwa semua model CNN dan *ensemble* CNN memiliki nilai *precision* dan *recall* yang cukup baik. Walaupun pada beberapa model CNN ada yang tidak terlalu bagus. Namun, untuk metode *ensemble* CNN skor terendah yang didapatkan adalah 0.71, dimana ini lebih tinggi daripada beberapa model CNN lainnya.

## V. KESIMPULAN

Berdasarkan hasil *training* dengan menggunakan data citra daun tomat sebanyak 1200 gambar dan 6 model CNN yang kemudian diterapkan metode *ensemble* menunjukkan performansi yang sangat baik dengan akurasi tertinggi adalah 0,9083 pada masing-masing model CNN dan *ensemble* CNN. Kemudian untuk nilai *precision* dan *recall* pada masing-masing model CNN dan *ensemble* CNN juga mendapatkan hasil yang baik diatas 0,8 hingga 1,0. Namun, secara umum dengan menggunakan metode *ensemble* CNN hasil yang didapatkan lebih baik daripada 6 model CNN dalam melakukan klasifikasi penyakit pada data citra daun tanaman tomat.

## UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan kepada Institut Teknologi Bacharuddin Jusuf Habibie yang telah memberikan kesempatan bagi penulis menyelesaikan penelitian ini. Penulis juga mengucapkan terima kasih kepada Wakil Rektor bidang Akademik sekaligus mentor atas bantuannya selama penelitian ini berlangsung.

## REFERENSI

- [1] Belén Picó, María José Díez, and Fernando Nuez, “Viral diseases causing the greatest economic losses to the tomato crop. ii. the tomato yellow leaf curl virus a review,” *Sci. Hortic.*, vol. 67, no. 3–4, pp. 151–196, 1996.
- [2] Jesús Navas-Castillo, Sonia Sánchez-Campos, Juan Antonio Díaz, Elisa Sáez-Alonso, and Enrique Moriones, “Tomato yellow leaf curl virus is causes a novel disease of common bean and severe epidemics in tomato in spain,” *Plant Dis.*, vol. 83, pp. 29–32, 1999.
- [3] Enrique Moriones and Jesús Navas-Castillo, “Tomato yellow leaf curl virus, an emerging virus complex causing epidemics worldwide,” *Virus Res.*, vol. 71, pp. 123–134, 2000.
- [4] Mohit Agarwal, Abhishek Singh, Siddhartha Arjaria, Amit Sinha, and Suneet Gupta, “ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network,” *Procedia Comput. Sci.*, vol. 167, pp. 293–301, 2020.
- [5] Nemanja Milosevic, *Introduction to Convolutional Neural Networks: With Image Classification Using PyTorch*. Apress, 2020.
- [6] Ali Yazdizadeh, Zachary Patterson, and Bilal Farooq, “Ensemble Convolutional Neural Networks for Mode Inference in Smartphone Travel Survey,” *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 6, pp. 2232–2239, 2020.
- [7] Vijai Singh and A.K. Misra, “Detection of Plant Leaf Disease using Image Segmentation and Soft Computing Techniques,” *Inf. Process. Agroculture*, vol. 4, pp. 41–49, 2017.
- [8] Hülya Yalçın and Salar Razavi, “Plant classification using convolutional neural networks,” presented at the International Conference on Agro-geoinformatics (Agro-geoinformatics), Tianjin, 2016.
- [9] Sagar Vetal and Rupali Khule, “Tomato Plant Disease Detection using Image Processing,” *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 6, no. 6, pp. 293–297, 2017.
- [10] Aravind Krishnaswamy Rangarajan, Raja Purushothaman, and Anirudh Ramesh, “Tomato crop disease classification using pre-trained deep learning algorithm,” presented at the International Conference on Robotics and Smart Manufacturing, Calgary, 2018.
- [11] Wei Chen, Qiang Sun, Jue Wang, Jing-Jing Dong, and Chen Xu, “A Novel AdaBoost and CNN Base for Vehicle Classification,” *IEEE Access*, vol. 6, pp. 60445–60455, 2018.
- [12] Shuo Yang, Li-Fang Chen, Tao Yan, Yun-Hao Zhao, and Ye-Jia Fan, “An Ensemble Classification Algorithm for Convolutional Neural Network based in AdaBoost,” presented at the International Conference on Computer and Information Science, Wuhan, 2017.