

Automated Fruit Classification Menggunakan Model VGG16 dan MobileNetV2

¹Umnny Salamah, ²Anita Ratnasari, ³Sarwati Rahayu

^{1,2,3}Universitas Mercu Buana, Indonesia

umniy.salamah@mercubuana.ac.id

Article Info

Article history:

Received, 2022-07-28

Revised, 2022-11-09

Accepted, 2022-11-22

Kata Kunci:

Fruit,

Classification,

VGG16

MobileNetV2

ABSTRAK

Pengembangan robot atau mesin untuk membantu kegiatan pertanian memerlukan riset yang panjang. Teknologi tersebut harus dapat memiliki keahlian dalam melakukan berbagai macam aktivitas dan mampu mendeteksi objek yang menjadi sasaran pekerjaannya. Untuk memenuhi hal ini, riset untuk mendeteksi objek pertanian, misalnya buah, menjadi salah satu agenda riset yang perlu dilakukan dan dikembangkan. Tujuan penelitian ini adalah untuk mengetahui hasil perbandingan performa deep learning yaitu VGG16 dan MobileNetV2 untuk fruit classification. Penelitian ini menggunakan dataset dengan jumlah total 90.483 data dengan ukuran gambar 100x100 piksel dan jumlah kelas tanaman buah yang akan diklasifikasi adalah sebanyak 131 kelas. Pada proses testing menggunakan dataset yang ada, MobileNetV2 mendapatkan akurasi 98,4% dan ResNet50 mendapatkan akurasi 99,2%.

ABSTRACT

Keywords:

Fruit,

Classification,

VGG16

MobileNetV2

The development of robots or machines to assist agricultural activities requires a long research. The technology must be able to have expertise in carrying out various activities and be able to detect objects that are the target of the work. To fulfill this, research to detect agricultural objects, such as fruit, is one of the research agendas that needs to be carried out and developed. The purpose of this study was to determine the results of the comparison of deep learning performance, namely VGG16 and MobileNetV2 for fruit classification. This study uses a dataset with a total of 90,483 data with an image size of 100x100 pixels and the number of classes of fruit plants to be classified is 131 classes. In the testing process using the existing dataset, MobileNetV2 got 98.4% accuracy and ResNet50 got 99.2% accuracy.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Umnny Salamah

Fakultas Ilmu Komputer

Universitas Mercu Buana, Indonesia

Email: umniy.salamah@mercubuana.ac.id

1. PENDAHULUAN

Teknologi pertanian saat ini sudah semakin berkembang untuk melibat robot dalam berbagai aktivitas pertanian. Di beberapa negara, tenaga kerja manusia untuk melakukan aktivitas pertanian membutuhkan biaya yang sangat tinggi. Beberapa industri pertanian bahkan telah mengurangi penggunaan keterlibatan manusia dalam kegiatan pertanian dan menggantinya dengan mesin yang sudah ditanamkan beberapa keahlian di [1], [2], [11]–[20], [3]–[10].

Pengembangan robot atau mesin untuk membantu kegiatan pertanian memerlukan riset yang panjang. Teknologi tersebut harus dapat memiliki keahlian dalam melakukan berbagai macam aktivitas dan mampu mendeteksi objek yang menjadi sasaran pekerjaannya. Untuk memenuhi hal ini, riset untuk mendeteksi objek pertanian, misalnya buah, menjadi salah satu agenda riset yang perlu dilakukan dan dikembangkan [1], [21]–[24].

Machine learning dan image processing adalah bidang yang cukup banyak dibahas untuk menambahkan kemampuan robat dalam mengenali sebuah objek. Banyak metode telah ditemukan dan dikembangkan, misalnya mengenali objek untuk membantu proses panen atau menentukan stok hasil panen secara otomatis [1]. Penelitian ini akan membahas mengenai salah satu proses obyek recognition dalam bidang pertanian, yaitu buah [25]–[29].

Penelitian oleh Duong et al. (2020) membahas mengenai fruit recognition menggunakan pendekatan deep learning. Model deep learning yang digunakan dalam eksperimen ini adalah EfficientNet and MixNet. Penelitian ini menggunakan dataset citra sebanyak 65.326 gambar (48.905 untuk proses training dan 16.421 untuk proses testing). Dari hasil eksperimen, studi ini mengklaim bahwa hasil akurasi yang didapatkan mencapai 99.13%–99.98% [1].

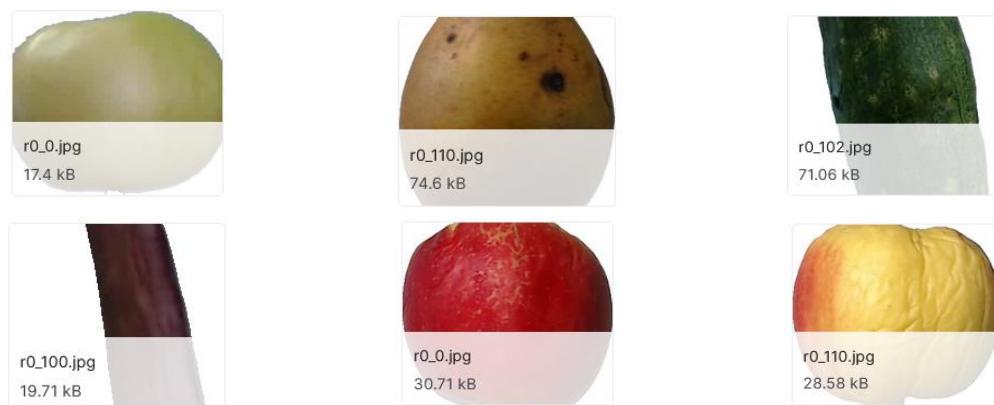
Penelitian oleh Hou et al. (2016) mengembangkan model fruit recognition algorithm berbasis deep learning. Metode yang digunakan adalah metode convolution neural network (CNN) yang digabungkan dengan metode selective search. Eksperimen dilakukan menggunakan dataset fruit images yang terdiri dari 5330 gambar (4000 data untuk proses training dan 1330 data untuk proses testing). Riset ini berhasil mendapat akurasi sebesar 99.77% untuk proses fruit image recognition [30].

Penelitian oleh Mia et al. (2019) menggunakan metode machine learning untuk local fruit recognition. Metode penelitian yang digunakan adalah metode support vector machines (SVMs). Dataset eksperimen terdiri dari enam kelas yaitu sugar-apple (ata), elephant apple (chalta), amla (amloki), bilombo, orboroi dan sapota (sopheda). Penelitian ini mendapatkan akurasi sebesar 94.79% [31].

Berdasarkan latar belakang penelitian diatas, studi ini bertujuan untuk menggunakan metode deep learning yaitu VGG16 dan MobileNetV2 untuk fruit classification. Penelitian ini menggunakan dataset dengan jumlah total 90.483 data dengan ukuran gambar 100x100 piksel dan jumlah kelas tanaman buah yang akan diklasifikasi adalah sebanyak 131 kelas.

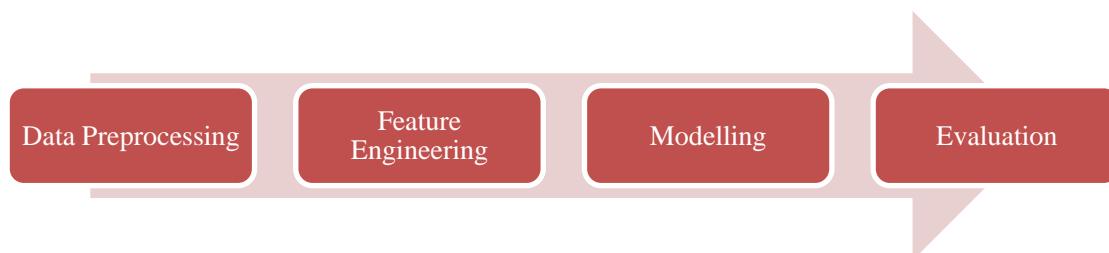
2. METODE PENELITIAN

Dataset yang digunakan dalam penelitian ini dengan jumlah total 90.483 data dengan ukuran gambar 100x100 piksel. Data pelatihan terdiri dari 67692 data dan data pengujian berjumlah 22688 data. Jumlah kelas tanaman buah yang akan diklasifikasi adalah sebanyak 131 kelas. Contoh dataset dapat dilihat pada Gambar berikut ini.



Gambar 1 Contoh Dataset

Adapun tahapan penelitian adalah Data Preprocessing, Feature Engineering, Modelling dan Evaluation seperti yang ada pada Gambar berikut ini.



Gambar 2 Tahapan Penelitian

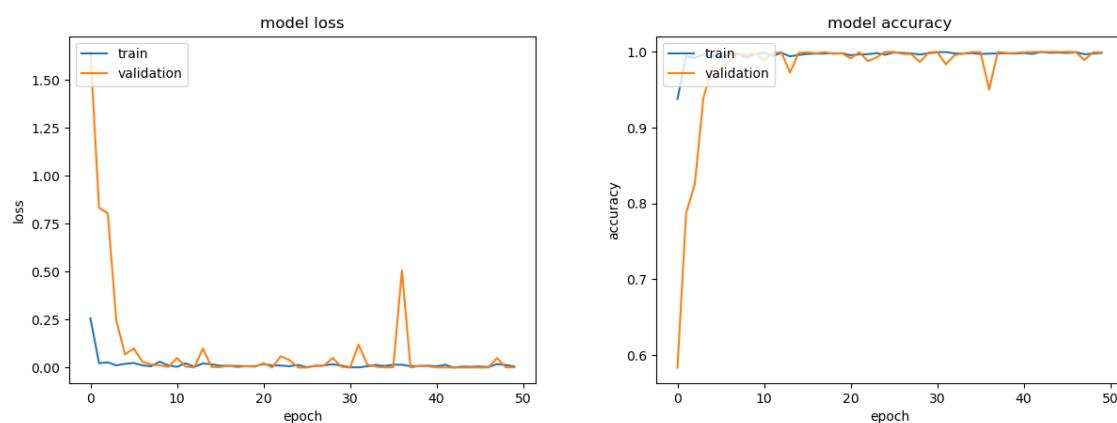
Model yang akan diuji coba pada eksperimen ini adalah dua model regresi yaitu VGG16 dan MobileNetV2. Dataset dibagi menjadi data training dan data testing. Pada tahap ini data akan dibagi menjadi 70% untuk training, 30% untuk testing untuk validasi. Tahap selanjutnya adalah pelatihan model. Pada tahap ini akan dilatih model dalam memetakan fitur dengan target pada data pelatihan. Selanjutnya pada tahap ini akan dilakukan testing pada model yang telah dihasilkan dengan data uji.

3. HASIL DAN ANALISIS

Dataset merupakan open public dataset terdiri dari total 22495, dengan training set sebanyak 16854, dan testing set sebanyak 5641. Dataset terdiri dari 33 kelas yang merupakan jenis buah-buahan dan sayur-sayuran. Ukuran images masing-masing adalah 100x100 piksel. Kebanyakan gambar juga diputar (*rotate*), untuk membantu pelatihan.

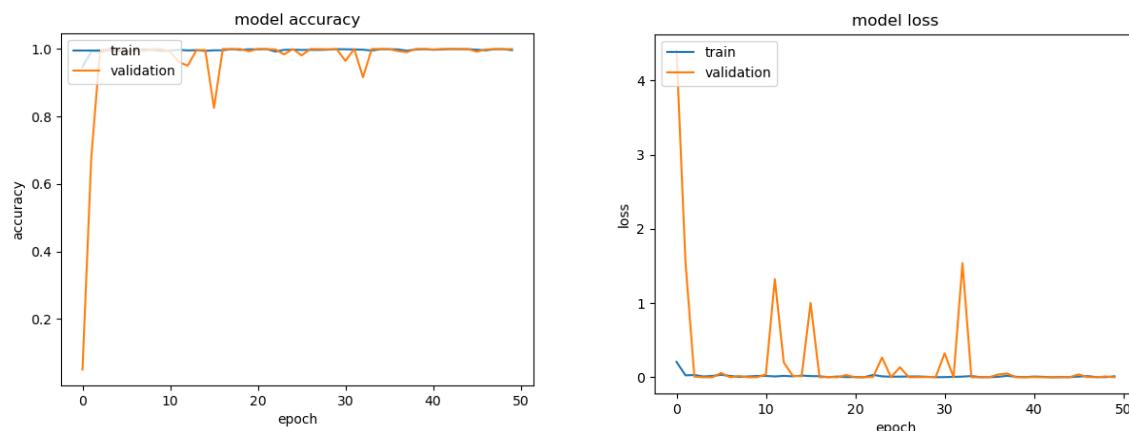
Parameter yang digunakan pada penelitian ini adalah Batch_size = 32, Input_shape = (224, 224, 3), epoch = 50, optimizer = Adam, Learning_rate = 0.0001. Pada penelitian ini kami membagi dataset Training kedalam data Training dan Validation dengan persentase 80% data training dan 20% data testing sehingga untuk data training sebanyak 13493 dan data validation sebanyak 3361. Untuk data testing kami hanya mengambil 1416 data dari 5641 data testing yang ada.

Pada proses training, validating dan evaluation, MobileNetV2 diproses sebanyak 50 epoch. Pada epoch pertama, akurasi cukup rendah namun meningkat pada epoch terakhir. Pada model dengan MobileNetV2, epoch pertama meraih akurasi validasi 0.58363 dan mencapai akurasi validasi 1.00 pada epoch ke-24 seperti yang terlihat pada Gambar berikut ini.



Gambar 3 Model Loss dan Akurasi MobileNetV2

Pada model dengan ResNet50, epoch pertama meraih akurasi validasi 0.05000 dan mencapai akurasi validasi 1.00 pada epoch ke-4. Pada proses training, validating dan evaluation, ResNet50 diproses sebanyak 50 epoch. Pada epoch pertama, akurasi cukup rendah namun meningkat pada epoch terakhir.



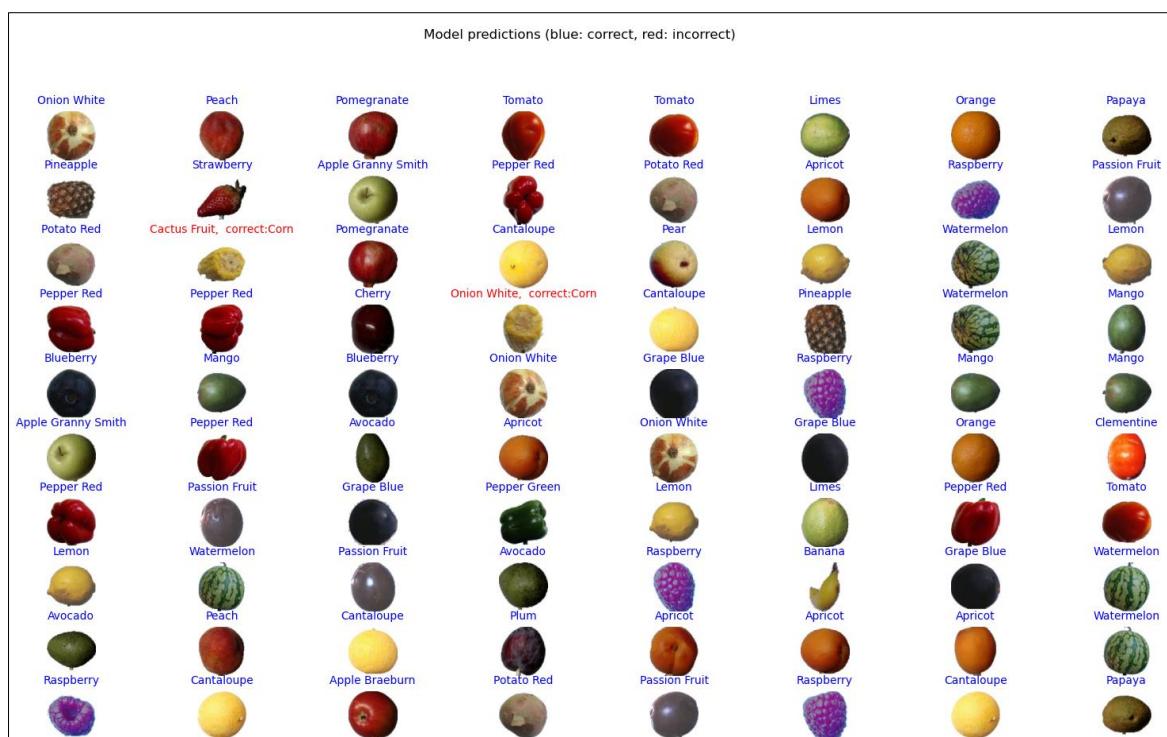
Gambar 4 Model Loss dan Akurasi ResNet50

Pada proses testing menggunakan dataset yang ada, MobileNetV2 mendapatkan akurasi 98.4% dan ResNet50 mendapatkan akurasi 99,2%. Untuk Cohens Kappa, MobileNetV2 mendapatkan nilai 0.983364 dan ResNet50 mendapatkan nilai 0.991704. Untuk F1-Score, MobileNetV2 mendapatkan nilai 0.981249 dan ResNet50 mendapatkan nilai 0.992667. Untuk Precision dan Recall, MobileNetV2 mendapatkan nilai 0.9874 dan 0.9840 sedangkan ResNet50 mendapatkan nilai 0.9960 dan 0.9920 seperti yang terlihat pada Tabel berikut ini.

Tabel 1 Hasil Evaluasi Kinerja MobileNetV2 dan ResNet50

Model	Testing Accuracy	Cohens Kappa	F1_score	Precision	Recall
MobileNetV2	0.984000	0.983364	0.981249	0.9874	0.9840
ResNet50	0.992000	0.991704	0.992667	0.9960	0.9920

Pada saat testing, model dengan MobileNetV2 berhasil memprediksi secara benar 78 buah dari total 80 buah pada data testing. Sebanyak 78 terprediksi benar dan 2 terprediksi salah. Pada model ini masih salah memprediksi jenis Corn yang terprediksi sebagai Cactus Fruit dan Onion White. Hasil prediksi dapat dilihat pada Gambar berikut ini.



Gambar 5 Hasil Prediksi MobileNetV2

4. KESIMPULAN

Pengembangan robot atau mesin untuk membantu kegiatan pertanian memerlukan riset yang panjang. Teknologi tersebut harus dapat memiliki keahlian dalam melakukan berbagai macam aktivitas dan mampu mendeteksi objek yang menjadi sasaran pekerjaannya. Untuk memenuhi hal ini, riset untuk mendeteksi objek pertanian, misalnya buah, menjadi salah satu agenda riset yang perlu dilakukan dan dikembangkan. Tujuan penelitian ini adalah untuk mengetahui hasil perbandingan performa deep learning yaitu VGG16 dan MobileNetV2 untuk fruit classification. Penelitian ini menggunakan dataset dengan jumlah total 90.483 data dengan ukuran gambar 100x100 piksel dan jumlah kelas tanaman buah yang akan diklasifikasi adalah sebanyak 131 kelas. Pada proses testing menggunakan dataset yang ada, MobileNetV2 mendapatkan akurasi 98.4% dan ResNet50 mendapatkan akurasi 99,2%.

UCAPAN TERIMA KASIH

Terima kasih kepada Pusat Penelitian (Biro Penelitian, Pengabdian Masyarakat & Publikasi UMB) yang telah mendanai penelitian ini dengan kontrak penelitian 02-5/892/B-SPK/III/2022

REFERENSI

- [1] L. T. Duong, P. T. Nguyen, C. Di Sipio, and D. Di Ruscio, "Automated fruit recognition using EfficientNet and MixNet," *Comput. Electron. Agric.*, vol. 171, p. 105326, 2020.
- [2] C. Lunner-Kolstrup, T. Hörndahl, and J. P. Karttunen, "Farm operators' experiences of advanced technology and automation in Swedish agriculture: A pilot study," *J. Agromedicine*, vol. 23, no. 3, pp. 215–226, 2018.
- [3] A. Rani, A. Chaudhary, N. Sinha, M. Mohanty, and R. Chaudhary, "Drone: The green technology for future agriculture," *Har. Dhara*, vol. 2, no. 1, pp. 3–6, 2019.
- [4] F. Klauser, "Surveillance farm: Towards a research agenda on big data agriculture," *Surveill. Soc.*, vol. 16, no. 3, pp. 370–378, 2018.
- [5] M. S. Farooq, S. Riaz, A. Abid, T. Umer, and Y. Bin Zikria, "Role of IoT technology in agriculture: A systematic literature review," *Electronics*, vol. 9, no. 2, p. 319, 2020.
- [6] I. Ranggadara, Y. S. Sari, S. Dwiasnati, and I. Prihandi, "A Review of Implementation and Obstacles in Predictive Machine Learning Model at Educational Institutions," in *Journal of Physics: Conference Series*, 2020, vol. 1477, p. 32019.
- [7] Y. Devianto and S. Dwiasnati, "Application electronic marketing to help marketing leading products village," *GSC Adv. Eng. Technol.*, vol. 1, no. 1, pp. 65–74, 2021.
- [8] S. Dwiasnati and Y. Devianto, "Utilization of Prediction Data for Prospective Decision Customers Insurance Using the Classification Method of C. 45 and Naive Bayes Algorithms," in *Journal of Physics: Conference Series*, 2019, vol. 1179, no. 1, p. 12023.
- [9] I. H. Ikasari, V. Ayumi, M. I. Fanany, and S. Mulyono, "Multiple regularizations deep learning for paddy growth stages classification from LANDSAT-8," in *International Conference on Advanced Computer Science and Information Systems (ICACSYS)*, 2016, pp. 512–517.
- [10] P. Sukmasetya, F. Nurhidayati, I. Permatasari, A. Rahmah, D. I. Sensuse, and H. Noprisson, "Developing mobile expert web-based system using brainstorming method: Case: Tetanus and botulism diagnosis and treatment in goat," *2017 Int. Conf. Inf. Technol. Syst. Innov. ICITSI 2017 - Proc.*, vol. 2018-Janua, pp. 303–308, 2017.
- [11] V. Ayumi and H. Noprisson, "Rancang Bangun Aplikasi Monitoring Pemberian Obat Bagi Pasien," *J. Sci. Appl. Informatics*, vol. 1, no. 1, pp. 8–12, 2018.
- [12] I. Nurhaida *et al.*, "Implementation of Deep Learning Predictor (LSTM) Algorithm for Human Mobility Prediction," *Int. J. Interact. Mob. Technol.*, vol. 14, no. 18, p. 132, Nov. 2020.
- [13] V. Ayumi, "Studi Pendahuluan: Pengembangan Aplikasi m-BCARE Untuk Pasien Penderita Kanker Payudara," *JUSIBI (Jurnal Sist. Inf. dan E-Bisnis)*, vol. 3, no. 1, pp. 26–33, 2021.
- [14] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and M. Utami, "Hand-Woven Fabric Motif Recognition Methods: A Systematic Literature Review," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 90–95.
- [15] H. Noprisson *et al.*, "Influencing factors of knowledge sharing among students in Indonesia higher educational institutions," *2016 Int. Conf. Inf. Technol. Syst. Innov. ICITSI 2016 - Proc.*, pp. 3–8, 2017.
- [16] E. Hidayat, Lukman, H. Noprisson, D. I. Sensuse, Y. G. Sucahyo, and E. D. Putra, "Development of mobile application for documenting traditional knowledge in Indonesia: A Case Study of Traditional Knowledge in Using Medicinal Plant," in *Proceedings - 14th IEEE Student Conference on Research and Development: Advancing Technology for Humanity, SCOReD 2016*, 2017.
- [17] A. A. Pratama, D. I. Sensuse, and H. Noprisson, "A systematic literature review of business process improvement," in *Information Technology Systems and Innovation (ICITSI), 2017 International Conference on*, 2017, pp. 26–31.
- [18] D. I. Sensuse, Y. G. Sucahyo, M. Silalahi, I. A. Wulandari, I. F. Akmaliah, and H. Noprisson, "Toward to operationalization of socio-technical ontology engineering methodology," in *2017 5th International Conference on Cyber and IT Service Management (CITSM)*, 2017, pp. 1–7.
- [19] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, "A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [20] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, "Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification," *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [21] J. P. Vasconez, G. A. Kantor, and F. A. A. Cheein, "Human–robot interaction in agriculture: A survey and current challenges," *Biosyst. Eng.*, vol. 179, pp. 35–48, 2019.
- [22] A. English, P. Ross, D. Ball, and P. Corke, "Vision based guidance for robot navigation in agriculture," in *2014 IEEE International Conference on Robotics and Automation (ICRA)*, 2014, pp. 1693–1698.
- [23] N. Noguchi and O. C. Barawid Jr, "Robot farming system using multiple robot tractors in Japan agriculture," *IFAC Proc. Vol.*, vol. 44, no. 1, pp. 633–637, 2011.

- [24] C. Zhang and N. Noguchi, "Development of a multi-robot tractor system for agriculture field work," *Comput. Electron. Agric.*, vol. 142, pp. 79–90, 2017.
- [25] H. Mureşan and M. Oltean, "Fruit recognition from images using deep learning," *Acta Univ. Sapientiae, Inform.*, vol. 10, no. 1, pp. 26–42, 2017.
- [26] S. T. Jagtap, K. Phasinam, T. Kassanuk, S. S. Jha, T. Ghosh, and C. M. Thakar, "Towards application of various machine learning techniques in agriculture," *Mater. Today Proc.*, 2021.
- [27] M. P. Raj, P. R. Swaminarayan, J. R. Saini, and D. K. Parmar, "Applications of pattern recognition algorithms in agriculture: a review," *Int. J. Adv. Netw. Appl.*, vol. 6, no. 5, p. 2495, 2015.
- [28] F. Pallottino *et al.*, "Machine vision retrofit system for mechanical weed control in precision agriculture applications," *Sustainability*, vol. 10, no. 7, p. 2209, 2018.
- [29] Q. Zhang, Y. Liu, C. Gong, Y. Chen, and H. Yu, "Applications of deep learning for dense scenes analysis in agriculture: A review," *Sensors*, vol. 20, no. 5, p. 1520, 2020.
- [30] L. Hou, Q. Wu, Q. Sun, H. Yang, and P. Li, "Fruit recognition based on convolution neural network," in *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 2016, pp. 18–22.
- [31] M. R. Mia, M. J. Mia, A. Majumder, S. Supriya, and M. T. Habib, "Computer vision based local fruit recognition," *Int. J. Eng. Adv. Technol.*, vol. 9, no. 1, pp. 2810–2820, 2019.