

## Implementasi Algoritma EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite untuk Sistem Deteksi Gulma

Nailul Muna<sup>1</sup>, Norma Ningsih<sup>1</sup>, Nanang Syahroni<sup>1</sup>, Abd. Malik Syamlan<sup>1</sup>, Vina Larasati<sup>1</sup>, Karimatun Nisa<sup>1</sup>

[nailul@pens.ac.id](mailto:nailul@pens.ac.id), [norma@pens.ac.id](mailto:norma@pens.ac.id), [nanang@pens.ac.id](mailto:nanang@pens.ac.id), [amsbox182@gmail.com](mailto:amsbox182@gmail.com),

[vinaaalarass@gmail.com](mailto:vinaaalarass@gmail.com), [nisa@pens.ac.id](mailto:nisa@pens.ac.id)

<sup>1</sup>Teknik Telekomunikasi, Departemen Teknik Elektro, Politeknik Elektronika Negeri Surabaya, Surabaya, Indonesia

### Informasi Artikel

Diterima : 23 Jan 2024  
Direview : 28 Jan 2024  
Disetujui : 20 Feb 2024

### Kata Kunci

Deep Learning, Deteksi Gulma, EfficientNet-D0, Pertanian Cerdas, SSD-MobileNet-V2 FPNLite

### Abstrak

Gulma merupakan tumbuhan yang tumbuh disekitar tanaman dan dapat merugikan tanaman yang dibudidayakan. Pengendalian gulma menjadi faktor penting yang dapat mempengaruhi produktivitas tanaman. Pengendalian gulma dapat ditanggulangi dengan melakukan penyemprotan pestisida pada gulma. Cakupan penyemprotan yang tepat sasaran dapat dilakukan untuk mencegah timbulnya masalah limbah. Sistem pertanian cerdas sangat dibutuhkan untuk mengatasi permasalahan tersebut, seperti deteksi gulma yang memanfaatkan teknik *deep learning*. Pada penelitian ini membangun sistem deteksi gulma yang mengimplementasikan EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite. Dataset yang digunakan berjumlah 941 citra gulma yang kemudian dilakukan pelabelan untuk data latih dan data uji. Sistem menunjukkan kinerja yang baik untuk mendeteksi gulma dengan *accuracy* berturut-turut dari EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite mencapai 95,69% dan 99,138%. Hasil tersebut menunjukkan EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite dapat mendukung dalam pengendalian gulma.

### Keywords

*Deep Learning, EfficientDet-D0, Smart Agriculture, SSD-MobileNet-V2 FPNLite, Weed Detection*

### Abstrak

*Weeds are plants that can interfere with cultivated plants. Weed control can be overcome by spraying pesticides on the weeds. Targeted spray coverage can be carried out to prevent waste problems from arising. Smart agricultural systems are needed to overcome these problems, such as weed detection using deep learning techniques. In this research, we build a weed detection system using a web camera installed on a Raspberry Pi. Images captured by the camera are processed by Raspberry Pi for the detection stage using EfficientDet-D0 and SSD-MobileNet-V2 FPNLite. The results of the detection process will be sent to the cloud server and stored in the database. Users can monitor it as a reference for dealing with growing weeds. The system shows good performance for detecting weeds with respective accuracy of EfficientDet-D0 and SSD-MobileNet-V2 FPNLite reaching 95.69% and 99.138%. These results show that EfficientDet-D0 and SSD-MobileNet-V2 FPNLite can support weed control.*

## A. Pendahuluan

Indonesia merupakan negara agraris yaitu sebagian mata pencaharian masyarakatnya adalah petani oleh karena itu sektor pertanian merupakan sektor yang sangat penting terhadap perekonomian nasional. Salah satu peran sektor pertanian adalah pemenuhan kebutuhan pangan, hal ini berbanding lurus dengan bertambahnya penduduk setiap tahun [1]–[3]. Dalam sektor pertanian, gulma merupakan tanaman yang tidak diinginkan serta mempengaruhi hasil dan kualitas tanaman [4]. Terdapat tiga jenis gulma berdasarkan bentuk daunnya, yakni gulma berdaun lebar, gulma berdaun sempit, dan teki [5]. Ancaman gulma yang sering dihadapi oleh para petani menyebabkan penyerapan air, unsur hara, dan ruang tumbuh yang tidak bisa optimal. Ancaman ini dapat menyebabkan hasil panen petani menurun [6], [7].

Gulma adalah ancaman yang sering terjadi bagi pertanian, Kehadiran gulma menciptakan persaingan dalam hal penyerapan air, unsur hara, ruang tumbuh dan sinar matahari yang berbahaya bagi tanaman. Selain itu, gulma melepaskan senyawa alelopati dan dapat menjadi inang bagi hama dan patogen tanaman. Kerugian yang disebabkan oleh gulma ini menurunkan hasil panen [8]. Oleh karena itu pengendalian gulma sangat penting untuk mempertahankan kualitas hasil tanaman. Salah satu cara untuk mengurangi ancaman ini adalah dengan cara menyemprot cairan pestisida. Namun saat ini penyemprotan pestisida disemprotkan ke seluruh area, yang mengakibatkan banyak limbah pestisida yang terbuang dan limbah dari penyemprotan menimbulkan resiko kesehatan serta menyebabkan kerusakan lingkungan [4], [5], [9].

Dalam beberapa tahun terakhir, perkembangan dan penerapan teknologi sensor, komputer teknologi, teknologi deteksi sudah banyak digunakan dalam berbagai aspek bidang salah satunya bidang pertanian. Salah satu yang dapat digunakan adalah teknologi *deep learning*. *Deep learning* merupakan salah satu turunan dari teknologi machine learning yang terinspirasi jaringan syaraf biologis manusia. Salah satu keuntungan *deep learning* adalah kemampuan untuk mempelajari data yang cukup besar. Salah satu implementasi deep learning adalah untuk mendeteksi objek tertentu [10]–[13].

EfficientDet merupakan metode *deep learning* yang digunakan untuk melakukan deteksi objek pada gambar atau video. Algoritma ini dikembangkan oleh tim *Google Research* dan merupakan salah satu algoritma yang paling akurat dan efisien saat ini dalam melakukan deteksi objek [14]. SSD-MobileNet-V2 FPNLite juga merupakan metode deep learning yang mana arsitekturnya hampir sama seperti SSD pada umumnya. Perbedaannya yaitu pada SSD ini arsitektur dasar menggunakan MobileNetV2. SSD-MobileNet-V2 FPNLite juga memiliki kemampuan dalam proses training yang cepat dengan hasil yang akurat [15].

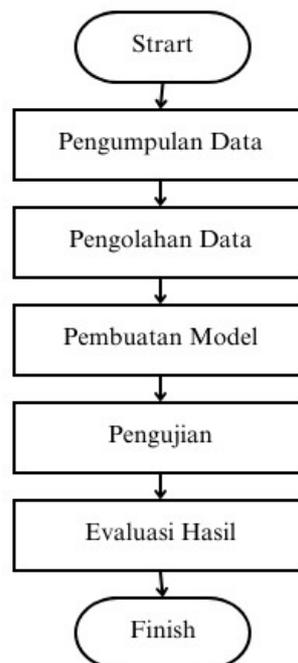
Sistem deteksi gulma menggunakan *deep learning* sebelumnya telah dilakukan oleh Jialin Yu, dkk yang berjudul “*Deep learning for image-based weed detection in turfgrass*”. Pada penelitian tersebut, sistem deteksi gulma dibangun menggunakan metode *Deep Convolutional Neural Network* (DCNN) dengan arsitektur DetecNet, GoogLeNet, dan VGGNet. DCNN dengan DetecNet memiliki performansi yang paling baik dalam sistem deteksi gulma yaitu memiliki nilai *F1 score* mencapai lebih dari 99% [10]. Lalu Kavir Osorio, dkk melakukan penelitian deteksi gulma yang berjudul “*A Deep Learning Approach for Weed Detection in Lettuce Crops Using Multispectral*

*Images*". Pada penelitian ini, penulis mengimplementasikan metode *Support Vector Machines* (SVM) menggunakan *Histogram of Oriented Gradient* (HOG), YOLOv3, dan Mask R-CNN. Hasil penelitian menyatakan hasil *F1-Score* dari tiga algoritma tersebut berturut-turut 88%, 94%, dan 94% [16]. Penelitian lainnya yaitu deteksi gulma menggunakan metode YOLO oleh Mino Sportelli dengan judul "*Evaluation of YOLO Object Detectors for Weed Detection in Different Turfgrass Scenarios*". Pada penelitian membandingkan beberapa metode YOLO seperti YOLOv5m, YOLOv6l, YOLOv7, YOLOv8l, dengan EfficientDet. Hasil penelitian tersebut menunjukkan bahwa YOLOv8 memiliki performansi paling tinggi dengan nilai *precision* mencapai 0,9476 [17].

Berdasarkan penelitian terdahulu, maka pada penelitian ini bermaksud untuk membuat sistem deteksi gulma dengan menerapkan dua algoritma *deep learning* yang belum digunakan oleh peneliti terdahulu untuk mendeteksi gulma, diantaranya algoritma EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite. Penelitian ini menggunakan *confusion matrix* untuk evaluasi pengujian. Evaluasi dilakukan untuk mengetahui kemampuan algoritma dalam mengukur akurasi deteksi gulma.

## B. Metode Penelitian

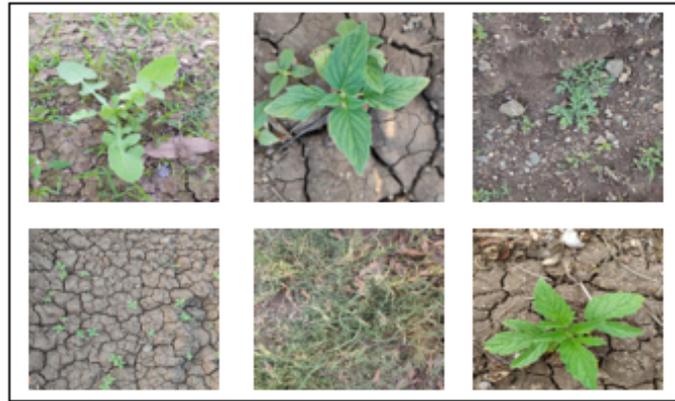
Pada penelitian ini terdapat beberapa tahapan yang akan dilakukan untuk dapat mendeteksi gulma pada kebun. Tahapan ini akan dijelaskan pada blok diagram metode penelitian seperti pada Gambar 1.



**Gambar 1.** Blok Diagram Metode Penelitian

### B.1. Pengumpulan data

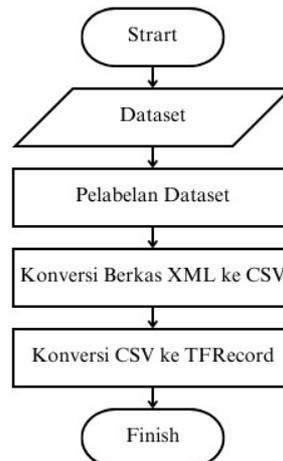
Pada penelitian ini data yang dikumpulkan berupa beberapa jenis gulma yang tumbuh pada kebun. Data yang dikumpulkan sejumlah 941 citra. Dataset yang digunakan terbagi menjadi 825 citra untuk data latih yang diambil dari Kaggle dan 116 citra gulma untuk data uji yang diambil langsung di kebun. Pada Gambar 2 menunjukkan sampel dataset yang digunakan pada sistem.



**Gambar 2.** Dataset Gulma

### B.2. Pengolahan Data

Terdapat beberapa tahapan yang dilakukan pada proses pengolahan data. Tahapan tersebut dimulai dari pelabelan dataset yang telah dikumpulkan yang disebut dengan anotasi data. Proses anotasi gambar menggunakan *software* Labelimg. Keluaran dari perangkat lunak Labelimg berupa titik koordinat dari *bounding box* yang disimpan dalam file dengan format *.xml*. Agar dapat diproses lebih lanjut berkas *.xml* dikonversi menjadi berkas dengan ekstensi *.csv*. Langkah selanjutnya mengkonversi berkas yang memiliki ekstensi *.csv* ke dalam berkas *TFRecord* (*TensorFlow Record*). Berkas *TFRecord* ini yang nanti akan digunakan untuk proses pelatihan. Gambar yang telah melalui proses anotasi data dibagi menjadi data pelatihan yang disimpan dalam folder *train\_images* dan data pengujian disimpan dalam folder *test-images*. Diagram alir pengolahan data ditampilkan pada Gambar 3.



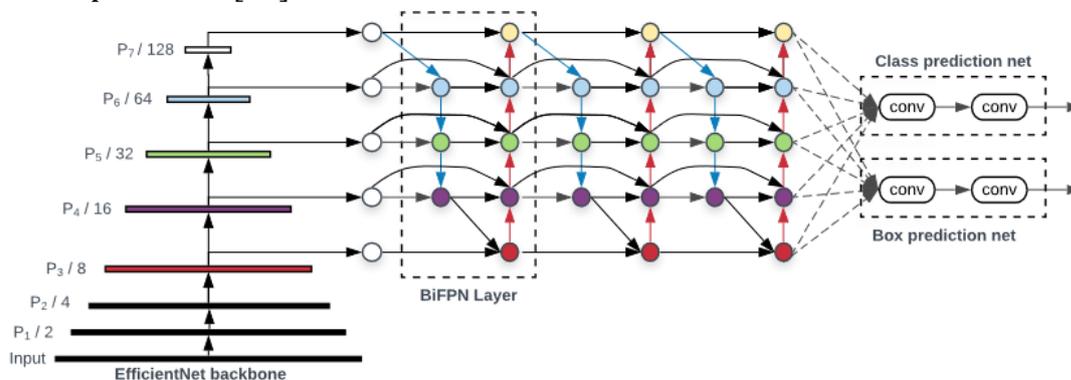
**Gambar 3.** Diagram alir pengolahan data

### B.3. Pembuatan Model

Proses pelatihan digunakan untuk membuat model yang nantinya akan diimplementasikan pada *hardware*. Proses pelatihan memanfaatkan platform Google Colab yang disediakan oleh google. Proses pelatihan menerapkan EfficientDet dan SSD MobileNet V2.

### B.3.1 EfficientDet-D0

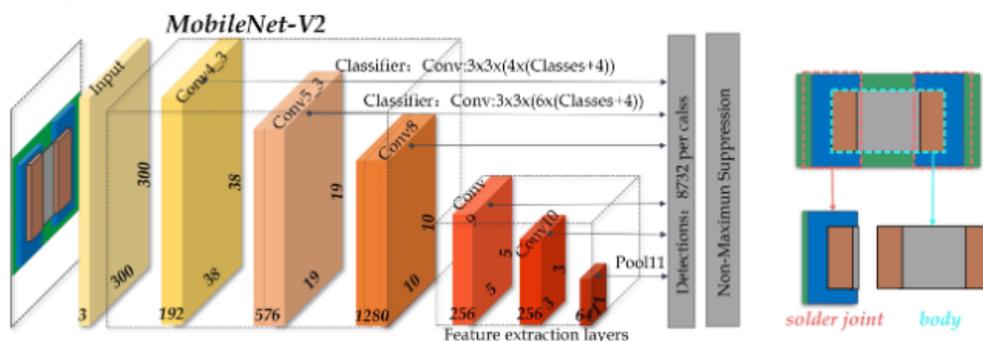
Gambar 4 menampilkan arsitektur EfficientDet yang merupakan detektor satu tahap. Jaringan dasarnya menggunakan EfficientNet-B0, dengan penerapan transfer learning dari ImageNet. Arsitektur ini memperkenalkan jaringan fitur baru yang disebut BiFPN, yang mengambil fitur Level 3–7 {P3, P4, P5, P6, P7} dari jaringan dasar dan menerapkan fusi fitur bidireksional dari bawah ke atas dan sebaliknya dari beberapa kali. Fitur-fitur yang telah digabungkan ini menjadi input untuk lapisan prediksi kelas dan kotak, yang bertanggung jawab atas klasifikasi objek dan pembuatan kotak pembatas. Jaringan dasar menggunakan koefisien penskalaan lebar/kedalaman yang sama dengan EfficientNet-B0, sehingga memudahkan penggunaan kembali titik kontrol ImageNet yang telah dilatih. Resolusi gambar input harus dapat dibagi habis dengan 27 karena Feature Levels 3–7 digunakan dalam proses ini [18].



Gambar 4. Arsitektur EfficientDet

### B.3.2 SSD-MobileNet-V2 FPNLite

Arsitektur SSD MobileNet V2 dapat dilihat pada Gambar 5. MobileNet V2 dipilih sebagai dasarnya untuk meningkatkan kecepatan deteksi dan mengurangi kompleksitas model. Selain itu, terdapat dua peningkatan untuk memenuhi kebutuhan deteksi secara real-time diantaranya penambahan tiga lapisan konvolusi setelah dasar MobileNetV2, dan modifikasi dimensi output dari lapisan konvolusi terakhir dari 256 menjadi 64. Perubahan pertama bertujuan untuk meningkatkan skala fitur dalam jaringan guna ekstraksi informasi fitur yang lebih baik. Sementara itu, perubahan kedua dilakukan untuk mengurangi jumlah referensi, sehingga mengurangi ukuran jaringan dan meningkatkan kecepatan komputasi [19].



Gambar 5. Arsitektur SSD MobileNet V2

#### B.4. Pengujian Sistem

Pengujian ini menggunakan gambar gulma yang telah diambil di area perkebunan. Gambar gulma yang digunakan untuk pengujian berjumlah 116 gambar. Pengujian deteksi gulma dilakukan menggunakan dua algoritma yaitu, EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite. Hasil kedua algoritma tersebut akan dievaluasi dan dianalisa.

#### B.5. Evaluasi

Evaluasi dilakukan dengan menghitung akurasi deteksi dengan cara mengambil parameter *True Positive* (TP), *False Positive* (FP), *True Negative* (TN) dan *False Negative* (FN). *True Positive* (TP) yaitu ketika *bounding box* berhasil mendeteksi gulma dengan benar. *False Positive* (FP) yaitu ketika *bounding box* dapat mendeteksi objek, tetapi bukan gulma. Dan *False Negative* (FN) yaitu *bounding box* tidak mendeteksi objek pada citra baik objek gulma maupun bukan. *True Negative* (TN) adalah jumlah data negatif yang terdeteksi dengan benar. *Confusion matrix* dari tiga parameter tersebut ditampilkan pada Gambar 6.

**Tabel 1. Confusion Matrix**

<i>Confusion Matrix</i>	Aktual YA	Aktual TIDAK
Prediksi YA	<i>True Positive</i> (TP)	<i>False Positive</i> (FP)
Prediksi TIDAK	<i>False Negative</i> (FN)	<i>True Negative</i> (TN)

Berdasarkan parameter TP, FP, FN, dan TN tersebut dapat diketahui nilai *precision*, *recall*, dan *Accuracy*. *Precision* merupakan tingkat akurasi deteksi yang dihasilkan oleh sistem. *Recall* adalah tingkat keberhasilan dalam melakukan deteksi. *Accuracy* merupakan ukuran yang digunakan untuk menemukan keseimbangan antara *precision* dan *recall* [20]. Nilai *precision*, *recall*, dan *accuracy* dapat diperoleh dari perhitungan berikut.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

#### C. Hasil dan Pembahasan

Pengujian menggunakan 116 citra gulma dengan mengimplementasikan dua algoritma yaitu EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite. Setiap algoritma terbagi kedalam tiga skenario dengan *batch size* yang berbeda. *Batch size* yang digunakan yaitu 4, 8, 16. Berdasarkan hasil pelatihan sesuai skenario tersebut, didapatkan nilai *Total Loss*. *Total Loss* merupakan suatu metrik yang mengukur sejauh mana model deteksi citra berhasil mengidentifikasi objek atau fitur tertentu dalam citra. Tujuan dalam pelatihan model deteksi citra adalah untuk

mengoptimalkan *total Loss* sehingga model dapat dengan akurat dan efisien mengenali objek dalam citra, mengidentifikasi lokasi objek, dan mengklasifikasikan objek ke dalam kategori yang benar. Semakin rendah *Total Loss*, semakin baik model dalam melakukan tugas deteksi citra. Total loss dari beberapa skenario ditampilkan pada Tabel 2.

**Tabel 2.** *Total loss* dari proses pelatihan

Model	Batch Size	Total Loss
EfficientDet-D0	4	0,5
	8	0,41
	16	0,34
SSD-MobileNet-V2 FPNLite	4	0,39
	8	0,46
	16	0,26

Tabel 2 menunjukkan ukuran *batch size* pada SSD-MobileNet-V2 FPNLite memiliki total loss yang lebih sedikit dibandingkan EfficientDet-D0. Berdasarkan skenario yang telah ditentukan, *total loss* model SSD-MobileNet-V2 FPNLite dengan ukuran *batch size* 16 bisa mencapai 0,26. Hal ini algoritma SSD-MobileNet-V2 FPNLite memiliki tingkat *error* yang kecil. Berdasarkan data yang diperoleh tersebut dapat diketahui bahwa ukuran *batch size* mempengaruhi *total loss* yang dihasilkan. Semakin besar ukuran *batch size* yang digunakan maka semakin kecil *Total Loss* yang didapatkan.

Evaluasi data pengujian dilakukan untuk melihat berapa banyak hasil deteksi yang bernilai *True Positive* (TP), *False Positive* (FP), *True Negative* (TN) dan *False Negative* (FN) dari sample 116 data yang sama dan dibandingkan pada masing-masing konfigurasi model yang digunakan. Dari hasil pengujian didapatkan data sebagai yang ditunjukkan pada Tabel 3.

**Tabel 3.** Hasil Matriks Evaluasi

Model	Batch Size	TP	FP	TN	FN
EfficientDet-D0	4	111	1	0	4
	8	101	2	0	13
	16	101	6	0	9
SSD-MobileNet-V2 FPNLite	4	106	5	0	5
	8	101	6	0	9
	16	115	1	0	0

Hasil matriks evaluasi yang ditampilkan pada Tabel 2 menunjukkan bahwa nilai TP pada kedua algoritma memiliki nilai tertinggi di bandingkan dengan parameter yang lainnya seperti FP, TN, dan FN. Hal ini menunjukkan sistem mampu mendeteksi gulma dengan tepat. Pada SSD-MobileNet-V2 FPNLite dengan *batch size* 16 memiliki kemampuan untuk mendeteksi gulma yang paling baik dengan nilai mencapai 115 yang dinyatakan dalam TP. Sedangkan nilai FP, TN, dan FN beturut-turut yaitu 1,0, dan 0.

Berdasarkan Tabel 3 dapat dilakukan perhitungan *precision*, *recall*, dan *accuracy* yang mengacu persamaan (1), (2), dan (3). Hasil perhitungan tersebut disajikan pada Tabel 4.

**Tabel 4.** Hasil uji coba performansi sistem

Model	Batch Size	Precision (%)	Recall (%)	Accuracy (%)
EfficientDet-D0	4	99,107	96,522	95,690
	8	98,058	88,596	87,069
	16	94,393	94,393	87,069
SSD-MobileNet-V2 FPNLite	4	95,495	95,495	91,379
	8	94,393	91,818	87,069
	16	99,138	100,000	99,138

Tabel 4 menyatakan nilai *precision*, *recall*, dan *accuracy* dari skenario yang ditentukan tidak ada perbedaan yang signifikan. Namun model SSD-MobileNet-V2 FPNLite memiliki nilai *precision*, *recall*, dan *accuracy* yang lebih baik dibandingkan EfficientDet-D0. Hal ini menunjukkan model SSD-MobileNet-V2 FPNLite dengan memiliki performansi yang paling baik dengan nilai *precision*, *recall*, dan *accuracy* berturut-turut mencapai 99,138%, 100%, dan 99,138%.

#### D. Simpulan

Pada penelitian ini membangun sistem deteksi gulma dengan menggunakan dataset sejumlah 941 citra yang terbagi menjadi 825 citra untuk data latih, dan 116 citra untuk data uji. Proses pelatihan dilakukan menggunakan algoritma EfficientDet-D0 dan SSD-MobileNet-V2 FPNLite. Ukuran *batch size* yang digunakan yaitu 4, 8, dan 16. Berdasarkan uji coba yang dilakukan SSD-MobileNet-V2 FPNLite dengan ukuran *batch size* 16 memiliki *total loss* mencapai 0,26 dan *accuracy* 99,138%. Hal ini menunjukkan nilai *total loss* berpengaruh terhadap *accuracy* sistem dalam mendeteksi objek gulma. Selain itu, performansi sistem juga dapat dipengaruhi oleh sejumlah faktor lain seperti dataset yang digunakan, tuning parameter, dan permasalahan deteksi citra yang dihadapi.

#### E. Ucapan Terima Kasih

Terima kasih kepada Politeknik Elektronika Negeri Surabaya yang telah memberikan pendanaan untuk penelitian ini dan semua pihak yang telah membantu dalam menyelesaikan penelitian.

#### F. Referensi

- [1] N. P. R. Aryawati and M. K. Sri Budhi, "Pengaruh Produksi, Luas Lahan, dan Pendidikan Terhadap Pendapatan Petani dan Alih Fungsi Lahan Provinsi Bali," *E-Jurnal EP UNUD*, vol. 7, no. 9, pp. 1918–1952, 2018.
- [2] E. Y. Dewi, E. Yuliani, and B. Rahman, "Analisis Peran Sektor Pertanian Terhadap Pertumbuhan Perekonomian Wilayah," *J. Kaji. Ruang*, vol. 2, no. 2, p. 229, 2022, doi: 10.30659/jkr.v2i2.20961.
- [3] S. I. Kusumaningrum, "Pemanfaatan Sektor Pertanian Sebagai Penunjang Pertumbuhan Perekonomian Indonesia," *J. Transaksi*, vol. 11, no. 1, pp. 80–89, 2019, [Online]. Available: <http://ejournal.atmajaya.ac.id/index.php/transaksi/article/view/477>.
- [4] H. Tamsan and Y. Yusriadi, "Quality of agricultural extension on productivity of farmers: Human capital perspective," *Uncertain Supply Chain Manag.*, vol. 10, no. 2, pp. 625–636, 2022, doi: 10.5267/j.uscm.2021.11.003.
- [5] H. Fitriyah and R. Maulana, "Deteksi Gulma Berdasarkan Warna HSV dan Fitur

- Bentuk Menggunakan Jaringan Syaraf Tiruan," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 5, p. 929, 2021, doi: 10.25126/jtiik.2021854719.
- [6] I. Vidya, L. Twenty, Krisyetno, and P. D. Satriyo, "Identifikasi Keragaman dan Dominansi Gulma pada Lahan Pertanaman Kedelai," *Agrotechnology Res. J.*, vol. 4, no. 1, 2020, doi: 10.20961/agrotechresj.v4i1.36449.
- [7] A. N. P. Riska and B. M. K. Sri, "Pengaruh Produksi, Luas Lahan, dan Pendidikan Terhadap Pendapatan Petani dan Alih Fungsi Lahan Provinsi Bali," *E-Jurnal EP Unud*, vol. 7, no. 9, pp. 1918–1952, 2018.
- [8] V. Imaniasita, T. Liana, and D. S. Pamungkas, "Identifikasi Keragaman dan Dominansi Gulma pada Lahan Pertanaman Kedelai," *Agrotechnology Res. J.*, vol. 4, no. 1, pp. 11–16, 2020, doi: 10.20961/agrotechresj.v4i1.36449.
- [9] J. Zhao, G. Tian, C. Qiu, B. Gu, K. Zheng, and Q. Liu, "Weed Detection in Potato Fields Based on Improved YOLOv4: Optimal Speed and Accuracy of Weed Detection in Potato Fields," *Electron.*, vol. 11, no. 22, 2022, doi: 10.3390/electronics11223709.
- [10] J. Yu, S. M. Sharpe, A. W. Schumann, and N. S. Boyd, "Deep learning for image-based weed detection in turfgrass," *Eur. J. Agron.*, vol. 104, no. November 2018, pp. 78–84, 2019, doi: 10.1016/j.eja.2019.01.004.
- [11] V. Kumar and M. L., "Deep Learning as a Frontier of Machine Learning: A Review," *Int. J. Comput. Appl.*, vol. 182, no. 1, pp. 22–30, 2018, doi: 10.5120/ijca2018917433.
- [12] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, 2021, doi: 10.1186/s40537-021-00444-8.
- [13] Y. Zhang, C. Song, and D. Zhang, "Deep Learning-Based Object Detection Improvement for Tomato Disease," *IEEE Access*, vol. 8, pp. 56607–56614, 2020, doi: 10.1109/ACCESS.2020.2982456.
- [14] J. Jia, M. Fu, X. Liu, and B. Zheng, "Underwater Object Detection Based on Improved EfficientDet," *Remote Sens.*, vol. 14, no. 18, 2022, doi: 10.3390/rs14184487.
- [15] I. Z. Saiful Bahri *et al.*, "Interpretation of Bahasa Isyarat Malaysia (BIM) Using SSD-MobileNet-V2 FPNLite and COCO mAP," *Inf.*, vol. 14, no. 6, 2023, doi: 10.3390/info14060319.
- [16] K. Osorio, A. Puerto, C. Pedraza, D. Jamaica, and L. Rodríguez, "A Deep Learning Approach for Weed Detection in Lettuce Crops Using Multispectral Images," *AgriEngineering*, vol. 2, no. 3, pp. 471–488, 2020, doi: 10.3390/agriengineering2030032.
- [17] M. Sportelli *et al.*, "Evaluation of YOLO Object Detectors for Weed Detection in Different Turfgrass Scenarios," *Appl. Sci.*, vol. 13, no. 14, 2023, doi: 10.3390/app13148502.
- [18] D. Buongiorno *et al.*, "Object Detection for Industrial Applications: Training Strategies for AI-Based Depalletizer," *Appl. Sci.*, vol. 12, no. 22, 2022, doi: 10.3390/app122211581.
- [19] G. Yang *et al.*, "Garbage Classification System with YOLOV5 Based on Image Recognition," *2021 6th Int. Conf. Signal Image Process. ICSIP 2021*, vol. 1, no. January 2020, pp. 11–18, 2021, doi: 10.1109/ICSIP52628.2021.9688725.
- [20] A. Saleh, A. Ridwan, and M. K. Gibran, "Machine Learning and Fuzzy C-Means

Clustering for the Identification of Tomato Diseases," *Indones. J. Comput. Sci.*,  
vol. 12, no. 5, pp. 2401–2413, 2023, doi: 10.33022/ijcs.v12i5.3379.