

Analisis Kebutuhan Fitur Minimum pada Klasifikasi Lettuce dan Weed Berbasis Mobilenetv2 dan Support Vector Machine

^{1*}Akhmad Jayadi, ²Ahmad Rofi'i, ³Kurniawan Saputra

^{1,2,3}Manajemen Informatika, Politeknik Negeri Lampung, Lampung, Indonesia

*Corresponding author: akhmad.jayadi@polinela.ac.id¹

ABSTRAK

Received : 04 Januari 2026
Accepted : 28 Februari 2026
Published : 30 Maret 2026

Otomatisasi pembersihan gulma (weed) pada budidaya selada (lettuce) memerlukan sistem visi komputer yang ringan dan cepat agar dapat diimplementasikan pada perangkat mobile atau edge. Penelitian ini bertujuan untuk menganalisis jumlah fitur minimum yang diekstraksi dari arsitektur MobileNetV2 untuk melakukan klasifikasi selada dan gulma secara akurat. Fitur diekstraksi dari layer global average pooling MobileNetV2 menghasilkan 1.280 fitur dasar. Metode SelectKBest dengan kriteria Mutual Information digunakan untuk mereduksi dimensi fitur, diikuti dengan klasifikasi menggunakan Support Vector Machine (SVM) berbasis kernel Radial Basis Function (RBF). Hasil eksperimen menunjukkan bahwa model mampu mencapai akurasi 100% hanya dengan menggunakan 2 fitur minimum, yang merepresentasikan reduksi fitur sebesar 99,84%. Pengurangan fitur ini secara signifikan mempercepat waktu komputasi, menjadikannya sangat ideal untuk komputasi berbasis mobile di sektor smart agriculture.

Kata Kunci: Selada, Gulma, MobileNetV2, Seleksi Fitur, SVM

ABSTRACT

Automating weed removal in lettuce cultivation requires a lightweight and fast computer vision system for implementation on mobile or edge devices. This study aims to analyze the minimum number of features extracted from the MobileNetV2 architecture to accurately classify lettuce and weeds. Features extracted from the global average pooling layer of MobileNetV2 yielded 1,280 base features. The SelectKBest method with Mutual Information criteria was used to reduce the feature dimensionality, followed by classification using a Support Vector Machine (SVM) based on the Radial Basis Function (RBF) kernel. Experimental results showed that the model achieved 100% accuracy using only two minimum features, representing a feature reduction of 99.84%. This feature reduction significantly speeds up computation time, making it ideal for mobile-based computing in the smart agriculture sector.

Keywords: Lettuce, Weeds, MobileNetV2, Feature Selection, SVM

This is an open access article under the [CC BY-SA](#) license



1. PENDAHULUAN

Sektor pertanian modern saat ini tengah mengalami transformasi digital yang masif melalui integrasi teknologi Smart Agriculture (Harefa & Gunawan, 2024) berbasis Artificial Intelligence (AI) (Kasman et al., 2025). Salah satu tantangan terbesar yang dihadapi oleh para petani di komoditas hortikultura (Pitaloka, 2020), khususnya budidaya selada (lettuce), adalah gangguan tanaman liar atau gulma (weed) (Herman & Harjoko, 2015). Kehadiran gulma di sekitar area tanam tidak hanya merebut nutrisi tanah, air, dan sinar matahari yang dibutuhkan oleh selada, tetapi juga berpotensi menjadi inang bagi berbagai hama dan penyakit. Oleh karena itu, proses identifikasi dan pembersihan gulma sejak dini menjadi tahapan krusial yang harus dilakukan guna menjaga kualitas serta kuantitas hasil panen selada secara optimal.

Secara konvensional, proses penyiangan gulma masih sangat bergantung pada tenaga manusia secara manual atau penggunaan herbisida kimia dalam skala besar. Metode manual membutuhkan waktu yang lama, tenaga kerja yang besar, dan biaya operasional yang tidak sedikit, terlebih di tengah fenomena kelangkaan tenaga kerja pertanian saat ini. Di sisi lain, penggunaan herbisida secara menyeluruh tanpa seleksi (broad-spectrum) menimbulkan ancaman serius terhadap pencemaran lingkungan, degradasi mutu tanah, serta meninggalkan residu kimia berbahaya pada tanaman selada yang siap dikonsumsi. Atas dasar tersebut, diperlukan sebuah sistem otomatisasi berbasis visi komputer (computer vision) (Toberge & Curtis, 2013) yang mampu membedakan antara tanaman selada dan gulma secara mandiri dan presisi di lapangan.

Dalam beberapa tahun terakhir, teknologi Deep Learning, khususnya Convolutional Neural Networks (CNN) (Pradnyatama et al., 2025), telah membuktikan performa yang sangat luar biasa dalam tugas-tugas klasifikasi citra digital di sektor pertanian. Namun, model-model CNN konvensional yang memiliki parameter raksasa umumnya membutuhkan sumber daya komputasi yang besar (high-end GPU) untuk proses inferensinya. Ketika dihadapkan pada skenario implementasi di dunia nyata, sistem ini dituntut untuk dapat berjalan langsung pada perangkat bergerak (mobile devices) atau edge computing yang terpasang pada robot penyiang otomatis atau gawai milik petani. Keterbatasan kapasitas memori, daya baterai, dan kecepatan prosesor pada perangkat mobile menjadi hambatan utama dalam mengadopsi model Deep Learning yang kompleks secara lokal tanpa ketergantungan pada koneksi internet awan (cloud).

Untuk mengatasi kendala komputasi tersebut, penggunaan arsitektur jaringan yang ringan seperti MobileNetV2 (Sandler et al., 2019) menjadi salah satu opsi terbaik yang banyak diteliti saat ini. MobileNetV2 memanfaatkan struktur inverted residuals dan linear bottlenecks yang dirancang khusus guna meminimalkan beban kerja memori dengan tetap mempertahankan akurasi ekstraksi fitur yang tinggi. Melalui lapisan global average pooling, MobileNetV2 mampu mengekstrak karakteristik visual laten dari sebuah citra menjadi sebuah vektor representasi yang padat berdimensi 1.280 fitur (Alfan & Kumalasari, 2026). Kendati dimensi ini jauh lebih ringkas dibanding model CNN tradisional, angka 1.280 fitur dirasa masih memiliki redundansi informasi yang cukup tinggi apabila langsung disalurkan ke tahap klasifikasi akhir pada perangkat dengan spesifikasi sangat terbatas.

Redundansi fitur tidak hanya memperlambat waktu eksekusi komputasi (inference time), tetapi juga dapat memicu fenomena curse of dimensionality yang berpotensi menurunkan ketajaman generalisasi model pengklasifikasi. Oleh sebab itu, integrasi metode seleksi fitur (feature selection) menjadi langkah strategis yang sangat penting untuk mengeksplorasi batasan "Fitur Minimum". Dengan menerapkan algoritma seleksi fitur seperti SelectKBest yang berbasis pada metrik Mutual Information (MI) (Nurdiniyah et al., 2025), sistem dapat mengevaluasi dan memeringkat tingkat ketergantungan informasi dari setiap fitur terhadap label kelas target. Melalui eliminasi fitur-fitur yang tidak berkorelasi atau bersifat redundan, dimensi ruang laten dapat dipangkas secara ekstrem hingga menyisakan sekumpulan kecil fitur yang benar-benar paling diskriminatif.

Penelitian ini bertujuan untuk menganalisis dan menguji secara empiris konfigurasi jumlah fitur minimum yang diekstraksi dari MobileNetV2 untuk melakukan klasifikasi antara selada dan gulma secara akurat. Fitur-fitur hasil reduksi tersebut kemudian dipasangkan dengan algoritma Support Vector Machine (SVM) (Somantri et al., 2022) berbasis kernel Radial Basis Function (RBF) (Afifah et al., 2023) yang dikenal tangguh dalam memisahkan data pada dimensi rendah secara efisien. Kebaruan (novelty) dari penelitian ini terletak pada pembuktian batas minimum dimensionalitas fitur yang mampu mempertahankan performa model secara absolut tanpa mengorbankan akurasi. Hasil dari studi ini diharapkan dapat memberikan kontribusi signifikan dalam perancangan algoritma pengenalan objek pertanian yang sangat ringan, super cepat, dan optimal untuk diintegrasikan ke dalam ekosistem perangkat cerdas bergerak di masa depan.

2. METODE PENELITIAN

2.1 Dataset dan Pra-pemrosesan

Kualitas dan representasi data merupakan faktor fundamental dalam keberhasilan implementasi model pembelajaran mesin, khususnya dalam domain visi komputer pertanian. Dataset yang digunakan dalam penelitian ini difokuskan pada dua kelas objek utama yang memiliki urgensi tinggi dalam proses penyiangan otomatis, yaitu lettuce (tanaman selada) dan weed (gulma pengganggu). Seluruh sampel citra dikumpulkan dalam kondisi pencahayaan dan latar belakang yang bervariasi untuk merepresentasikan kondisi riil di lahan pertanian, sehingga model yang dilatih memiliki kemampuan generalisasi yang kuat.

Untuk keperluan eksperimen, dataset dibagi secara sistematis ke dalam dua bagian utama, yaitu data pelatihan (training data) dan data validasi/pengujian (validation/testing data). Data pelatihan terdiri dari total 446 citra, yang terdistribusi secara seimbang (balanced dataset) antara 223 citra untuk kelas selada dan 223 citra untuk kelas gulma. Distribusi yang seimbang pada data latih ini sangat krusial guna menghindari terjadinya bias klasifikasi, di mana model cenderung lebih mengenali kelas dengan jumlah sampel yang lebih dominan. Sementara itu, subset data validasi digunakan untuk menguji performa akhir dari kombinasi fitur hasil seleksi dan pengklasifikasi SVM. Data validasi ini mencakup 128 citra, dengan rincian komposisi terdiri dari 56 citra selada dan 72 citra gulma.

Sebelum citra dimasukkan ke dalam tahapan ekstraksi fitur menggunakan arsitektur deep learning, serangkaian proses pra-pemrosesan (preprocessing) wajib dilakukan untuk menyamakan format input standar. Tahap pertama adalah melakukan penyesuaian dimensi (resizing). Mengingat citra mentah dari lapangan memiliki resolusi dan rasio aspek yang beragam, seluruh citra diubah ukurannya secara digital menjadi resolusi seragam 224x224 piksel dengan saluran warna RGB (3 channels). Dimensi 224x224x3 ini merupakan ukuran masukan standar yang mutlak diperlukan oleh arsitektur MobileNetV2 agar proses perkalian matriks pada lapisan konvolusi dapat berjalan dengan tepat.


Setelah proses penyesuaian ukuran selesai, tahapan berikutnya adalah normalisasi nilai piksel menggunakan fungsi bawaan `preprocess_input` yang spesifik untuk arsitektur MobileNetV2. Secara teknis, fungsi ini melakukan penskalaan ulang (rescaling) nilai intensitas warna piksel asli yang semula berada pada rentang nilai integer 0 hingga 255. Nilai-nilai tersebut ditransformasikan secara matematis ke dalam rentang nilai floating-point antara -1 hingga 1, atau disesuaikan dengan distribusi normal berdasarkan rerata (mean) dan deviasi standar dari dataset ImageNet. Normalisasi ini memegang peranan penting untuk mempercepat konvergensi model, mencegah terjadinya fenomena exploding gradients, serta memastikan bahwa magnitudo nilai input berada pada skala tensor yang optimal saat melewati lapisan-lapisan inversi residual MobileNetV2.

2.2 Arsitektur Sistem Klasifikasi dan Seleksi Fitur

Sistem yang dibangun menggunakan alur kombinasi Deep Feature Extraction dan Machine Learning Classifier :

1. Ekstraksi Fitur: Citra dimasukkan ke dalam arsitektur dasar MobileNetV2 (pre-trained ImageNet) tanpa top layer dengan global average pooling, menghasilkan vektor fitur berdimensi 1x1280 per citra.
2. Seleksi Fitur Minimum: Menggunakan algoritma SelectKBest berbasis Mutual Information (MI). MI mengukur tingkat ketergantungan informasi antar fitur terhadap label kelas untuk menyaring k fitur paling informatif. Ukuran k diuji secara bertahap dari 1 hingga 1.280 fitur.
3. Klasifikasi: Menggunakan Support Vector Machine (SVM) dengan kernel RBF untuk memisahkan data selada dan gulma di ruang fitur baru.

Diagram arsitektur seperti yang terlihat pada Gambar X merupakan sistem yang menggambarkan transformasi data secara linear, mulai dari pemrosesan citra mentah di lapangan hingga menghasilkan keputusan akhir klasifikasi biner (lettuce atau weed). Proses ini terdiri dari 6 blok utama:



Gambar 1. Arsitektur Sistem

Proses identifikasi dalam penelitian ini diawali dengan penyediaan citra digital daun tanaman yang diambil langsung dari area lahan pertanian. Citra mentah tersebut tidak dapat langsung dimasukkan ke dalam sistem, melainkan harus melewati tahap pra-pemrosesan terlebih dahulu guna menyelaraskan dimensinya menjadi resolusi seragam 224 x 224 piksel dengan tiga saluran warna RGB. Pada tahapan awal ini, nilai intensitas setiap piksel citra disesuaikan dan dinormalisasi ke dalam rentang skala matematis antara -1 hingga 1. Langkah penyesuaian dan normalisasi ini sangat krusial demi memastikan bahwa data masukan berada dalam format tensor standar yang siap diproses secara optimal oleh lapisan-lapisan konvolusi pada tahapan berikutnya.

Setelah citra masukan berada dalam kondisi siap, data tersebut dialirkan menuju blok arsitektur MobileNetV2 yang bertindak sebagai tulang punggung (*backbone*) ekstraktor fitur mendalam. Di dalam blok ini, citra dilewatkan melalui serangkaian lapisan inverted residuals dan linear bottlenecks untuk menangkap berbagai karakteristik visual objek, mulai dari level rendah seperti garis tepi daun hingga level tinggi berupa pola urat dan tekstur kelopak. Tepat di ujung arsitektur MobileNetV2, lapisan klasifikasi bawaan ImageNet dipotong dan digantikan oleh lapisan Global Average Pooling (GAP). Lapisan GAP ini bertugas mereduksi dimensi spasial peta fitur terakhir menjadi sebuah vektor satu dimensi yang sangat padat, yang dikenal sebagai Deep Features Vector dengan dimensi tepat sebesar 1.280 fitur.

Vektor berdimensi 1.280 ini sejatinya telah merepresentasikan karakteristik numerik unik dari tanaman selada maupun gulma. Namun, ruang fitur yang besar ini masih menyimpan redundansi informasi yang tinggi, yang berpotensi membebani kapasitas memori dan memperlambat komputasi pada perangkat mobile. Untuk mengatasi kendala tersebut, vektor dipindahkan ke dalam blok penyaringan menggunakan kombinasi algoritma SelectKBest dan metrik statistik Mutual Information (MI). Di tahap ini, setiap komponen dari 1.280 fitur dihitung skor ketergantungannya terhadap label kelas target, lalu diurutkan secara menurun. Algoritma kemudian mengeksplorasi batas minimum dan hanya meloloskan sejumlah k fitur dengan skor tertinggi, sementara fitur lainnya dieliminasi secara permanen.

Berdasarkan hasil pengujian empiris yang telah dilakukan, ambang batas jumlah fitur paling minimum yang ditemukan adalah sebesar $k = 2$. Hasil penyaringan ini melahirkan sebuah vektor baru super ringan yang hanya berdimensi 2, namun memiliki daya pemisah (*separability*) objek yang sangat kuat. Vektor fitur minimum berdimensi 2 inilah yang menjadi masukan akhir bagi blok pengklasifikasi Support Vector Machine (SVM). Dengan memanfaatkan fungsi kernel Radial Basis Function (RBF), SVM memetakan dua fitur tersebut ke dalam ruang matematis baru untuk membentuk sebuah bidang pembatas (*hyperplane*) optimal dengan margin maksimum. Melalui kalkulasi yang sangat cepat dan efisien pada ruang dimensi rendah tersebut, SVM berhasil mengeluarkan keputusan akhir berupa label biner yang akurat, yaitu mengklasifikasikan objek sebagai tanaman selada (*lettuce*) atau sebagai gulma pengganggu (*weed*).

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan dan menganalisis secara mendalam hasil eksperimen pencarian kebutuhan fitur minimum menggunakan arsitektur MobileNetV2, algoritma SelectKBest berbasis Mutual Information (MI), dan pengklasifikasi Support Vector Machine (SVM). Evaluasi performa sistem diukur menggunakan metrik standarisasi pengenalan citra digital, meliputi Accuracy, Precision, Recall, dan F1-Score. Selain berfokus pada tingkat ketepatan prediksi, aspek efisiensi waktu komputasi yang mencakup waktu pelatihan (training time) serta waktu inferensi (inference time) juga dibahas secara komprehensif guna membuktikan kelayakan implementasi algoritma pada perangkat keras dengan spesifikasi terbatas (edge computing).

3.1. Analisis Kuantitatif Kinerja Klasifikasi Berdasarkan Variasi Fitur

Eksperimen dilakukan secara bertahap dengan memanipulasi jumlah fitur terpilih (k) yang lolos dari seleksi Mutual Information, mulai dari konfigurasi terekstrem yaitu hanya menggunakan 1 fitur tunggal hingga memanfaatkan keseluruhan 1.280 fitur mendalam (deep features) hasil ekstraksi lapisan Global Average Pooling MobileNetV2. Seluruh performa model dievaluasi menggunakan data validasi independen yang tidak pernah dikenali oleh model sebelumnya selama fase pelatihan. Tabel 1 menyajikan data kuantitatif komparasi performa model klasifikasi SVM pada berbagai variasi jumlah fitur minimum.


Tabel 1. Perbandingan Performa Klasifikasi SVM Berdasarkan Jumlah Fitur Minimum

Jumlah Fitur (k)	Reduksi Fitur (%)	Akurasi	Precision
1	99.92%	0.9609	0.9641
2	99.84%	1.0000	1.0000
3	99.76%	0.9921	0.9923
5	99.61%	1.0000	1.0000
10	99.21%	1.0000	1.0000
50	96.09%	1.0000	1.0000
100	92.19%	1.0000	1.0000
1280 (Penuh)	0.00%	1.0000	1.0000

Berdasarkan data Tabel 1, ketika hanya menggunakan 1 fitur tunggal, akurasi klasifikasi berada pada nilai 96,09%. Performa melonjak secara maksimal menjadi 100% Akurasi tepat saat sistem menggunakan 2 fitur saja. Pengurangan dimensi dari 1.280 fitur menjadi 2 fitur merepresentasikan pemotongan beban memori sebesar 99,84%. Dampak langsung dari reduksi ini terlihat pada aspek efisiensi waktu komputasi:

1. Waktu Training: Menurun drastis dari 0,0221 detik (fitur penuh) menjadi 0,0018 detik.
2. Waktu Inferensi: Berhasil dipangkas dari 0,0074 detik menjadi 0,0004 detik.

sistem berhasil membuang 99,84% informasi sekunder yang redundan tanpa mengurangi sedikit pun ketajaman estimasi model. Perubahan performa model yang dipengaruhi oleh dimensionalitas jumlah fitur ini divisualisasikan secara jelas pada Gambar X berikut.



Gambar 2. Grafik Garis Akurasi vs Jumlah Fitur


Hanya dibutuhkan 2 fitur membuktikan bahwa ruang laten representasi objek MobileNetV2 sangat separable (mudah dipisahkan) untuk kasus membedakan selada dan gulma ini.

3.2. Analisis Efisiensi Waktu Komputasi dan Kebutuhan Perangkat Bergerak

Tujuan utama dari pencarian kombinasi fitur minimum adalah meminimalkan beban komputasi agar proses inferensi dapat berjalan secepat mungkin secara lokal. Oleh karena itu, pengamatan terhadap fluktuasi waktu pelatihan (training time) dan waktu pengujian (inference time) menjadi sangat krusial untuk dibahas.

Merujuk pada hasil simulasi pada lingkungan perangkat keras yang konstan, proses pelatihan model SVM menggunakan keseluruhan 1.280 fitur dasar membutuhkan waktu selama 0,0221 detik. Meskipun angka ini terlihat kecil dalam skala simulasi desktop, waktu tersebut akan terakumulasi secara signifikan jika model harus terus-menerus diperbarui secara dinamis di lapangan dengan volume data yang masif. Melalui pemangkasan dimensi menjadi hanya 2 fitur minimum, waktu pelatihan berhasil ditekan secara drastis hingga mencapai 0,0018 detik. Pangkasan waktu ini membuktikan bahwa beban kerja komputasi dalam fase optimasi kuadratik untuk mencari support vectors pada SVM menjadi jauh lebih sederhana ketika ruang fiturnya hanya berupa bidang dua dimensi.

Dampak yang jauh lebih nyata dan berharga untuk implementasi smart agriculture berbasis mobile terlihat pada metrik waktu inferensi per citra. Penggunaan seluruh fitur penuh 1.280 dimensi menghasilkan rata-rata waktu inferensi sebesar 0,0074 detik per gambar. Ketika fitur direduksi secara ekstrem menjadi 2 fitur minimum, waktu inferensi berhasil dipangkas hingga menyisakan 0,0004 detik (atau setara dengan 0,4 milidetik). Perbandingan efisiensi waktu pemrosesan yang sangat kontras ini disajikan pada grafik Gambar 4.



Gambar 3. Perbandingan Waktu Inferensi

Artinya, dalam satu detik komputasi lokal, model dengan konfigurasi fitur minimum ini secara teoritis mampu memproses hingga 2.500 frame citra tanaman. Kecepatan inferensi yang super cepat ini membuka peluang besar untuk integrasi sistem pada kamera video real-time berkecepatan tinggi yang terpasang pada robot penyiang mekanis, tanpa memicu kendala lagging atau panas berlebihan (overheating) pada prosesor gawai.

4. KESIMPULAN

Penelitian ini berhasil menjawab kebutuhan fitur minimum untuk klasifikasi selada dan gulma berbasis MobileNetV2. Melalui pemanfaatan algoritma SelectKBest berbasis Mutual Information, ditemukan bahwa 2 fitur minimum dari total 1.280 deep features sudah cukup bagi pengklasifikasi SVM untuk menghasilkan tingkat akurasi mutlak sebesar 100% pada data pengujian. Reduksi fitur sebesar 99,84% ini sukses memangkas waktu inferensi menjadi hanya 0,0004 detik. Temuan ini membuktikan konfigurasi fitur minimum tersebut sangat layak diaplikasikan langsung pada arsitektur perangkat cerdas bergerak (mobile/edge computing algorithm) karena minim konsumsi daya memori tanpa mengorbankan akurasi.

REFERENSI

- Afifah, N., Stiawan, D., & Bardadi, A. (2023). Perbandingan Kinerja Kernel RBF dan Linear pada Algoritma Support Vector Machine (SVM) untuk Prediksi Serangan Ransomware Locker. *JSI: Jurnal Sistem Informasi (E-Journal)*, 15(1), 3118–3123. <https://doi.org/10.18495/jsi.v15i1.113>
- Alfan, D. S., & Kumalasari, I. (2026). *Implementasi Model Deep Learning MobileNetV2 untuk Klasifikasi Citra Melanoma Berbasis Web*. 7(3), 670–680. <https://doi.org/10.47065/josh.v7i3.8848>
- Harefa, R. H., & Gunawan, H. (2024). Perancangan Smart Agriculture System Berbasis Internet of Things. *Digital Transformation Technology*, 4(1), 79–86. <https://doi.org/10.47709/digitech.v4i1.3647>
- Herman, H., & Harjoko, A. (2015). Pengenalan Spesies Gulma Berdasarkan Bentuk dan Tekstur Daun Menggunakan Jaringan Syaraf Tiruan. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 9(2), 207. <https://doi.org/10.22146/ijccs.7549>
- Kasman, R. A., Burhan, & Abdul Munir HB. (2025). Peran dan Tantangan Kecerdasan Buatan (AI) dalam Pendidikan Tinggi: Implementasi dan Implikasi Etis. *Jurnal Pendidikan Dan Pembelajaran*, 5(1), 24–33.

<https://doi.org/10.62388/jpdp.v5i1.523>

- Nurdiniyah, E., Aisya Nur Aulia Yusuf, Rahardian Luthfi Prasetyo, & Rasyida Shabihah Zukron Aini. (2025). Seleksi Fitur Berbasis Mutual Information untuk Optimalisasi Model Prediksi Tingkat Kematian Penderita Gagal Jantung Menggunakan Machine Learning. *Jurnal Ilmiah Teknik Mesin, Elektro Dan Komputer*, 5(2), 484–500. <https://doi.org/10.51903/juritek.v5i2.5044>
- Pitaloka, D. (2020). HORTIKULTURA: POTENSI, PENGEMBANGAN DAN TANTANGAN. *Jurnal Teknologi Terapan: G-Tech*, 1(1), 1–4. <https://doi.org/10.33379/gtech.v1i1.260>
- Pradnyatama, M., Sari, C. A., Rachmawanto, E. H., & Islam, H. M. M. (2025). A Comparative Analysis of Convolutional Neural Network (CNN): MobileNetV2 and Xception for Butterfly Species Classification. *Jurnal Masyarakat Informatika*, 16(1), 69–90. <https://doi.org/10.14710/jmasif.16.1.72957>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2019). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. <http://arxiv.org/abs/1801.04381>
- Somantri, O., Purwaningrum, S., & Riyanto, R. (2022). MODEL SUPPORT VEKTOR MACHINE (SVM) BERDASARKAN PARAMETER WINDOWS UNTUK PREDIKSI KEKUATAN GEMPA BUMI. *JTT (Jurnal Teknologi Terapan)*, 8(1), 17. <https://doi.org/10.31884/jtt.v8i1.352>
- Tobergte, D. R., & Curtis, S. (2013). Algorithms for image processing and computer vision. In *Journal of Chemical Information and Modeling* (Vol. 53, Issue 9). <https://doi.org/10.1017/CBO9781107415324.004>