

Evaluasi Kinerja *GoogleNet* Menggunakan *Transfer Learning* dan Fungsi Optimasi SGDM untuk Klasifikasi Citra Gulma

Weno Syechu¹, Rian Syahputra², Ahmad Indra Harahap³

¹ Teknik Komputer , Politeknik Negeri Medan, Medan, Indonesia

² Manajemen Infomatika , Politeknik Negeri Medan, Medan, Indonesia

³ Pendidikan Teknik Informatika , STKIP AL Maksu, Stabat, Indonesia

Article Info

Article history:

Received Januari 16, 2024

Revised Februari 30, 2024

Accepted April 30, 2024

Kata Kunci:

GoogleNet,
Transfer Learning,
Optimasi CNN,
Klasifikasi Gulma,
DeepWeeds

Keywords:

GoogleNet,
Transfer Learning,
CNN Optimization,
WeedClassification,
DeepWeeds

ABSTRAK

Identifikasi gulma secara cepat dan tepat merupakan elemen penting dalam pertanian presisi. Penelitian ini memfokuskan pada evaluasi arsitektur Convolutional Neural Network (CNN) *GoogleNet* dalam klasifikasi citra gulma menggunakan pendekatan transfer learning. Dataset *DeepWeeds* yang berisi 17.509 gambar digunakan dan diklasifikasikan ke dalam sembilan kelas gulma. Proses pelatihan dilakukan dengan membekukan semua layer kecuali layer fully-connected terakhir, yang disesuaikan dengan jumlah kelas. Fungsi optimasi Stochastic Gradient Descent with Momentum (SGDM) digunakan dalam proses pelatihan. Penelitian ini mengevaluasi kinerja arsitektur Convolutional Neural Network (CNN) *GoogleNet* menggunakan pendekatan transfer learning untuk klasifikasi citra gulma pada dataset *DeepWeeds* yang terdiri dari sembilan kelas gulma berbeda. Fungsi optimasi Stochastic Gradient Descent with Momentum (SGDM) digunakan selama pelatihan model. Hasil eksperimen menunjukkan bahwa model mencapai akurasi pengujian sebesar 92,38% dengan waktu klasifikasi rata-rata hanya 0,0365 detik per gambar. Studi ini memberikan kontribusi signifikan sebagai acuan penerapan deep learning efisien dalam sistem pertanian presisi.

ABSTRACT

Fast and accurate weed identification is an important element in precision agriculture. This study focuses on the evaluation of GoogleNet Convolutional Neural Network (CNN) architecture in weed image classification using transfer learning approach. DeepWeeds dataset containing 17,509 images was used and classified into nine weed classes. The training process was carried out by freezing all layers except the last fully-connected layer, which was adjusted according to the number of classes. Stochastic Gradient Descent with Momentum (SGDM) optimization function was used in the training process. This study evaluates the performance of GoogleNet Convolutional Neural Network (CNN) architecture using transfer learning approach for weed image classification on DeepWeeds dataset consisting of nine different weed classes. Stochastic Gradient Descent with Momentum (SGDM) optimization function was used during model training. The experimental results showed that the model achieved a test accuracy of 92.38% with an average classification time of only 0.0365 seconds per image. This study provides a significant contribution as a reference for the application of efficient deep learning in precision agriculture system.

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



Corresponding Author:

Weno Syechu
Teknik Komputer, Politeknik Negeri Medan
Medan, Indonesia
Email: wenosyechu@polmed.ac.id

1. PENDAHULUAN

Pertanian presisi merupakan pendekatan modern dalam dunia pertanian yang mengintegrasikan teknologi tepat guna untuk meningkatkan efisiensi produksi serta menjaga keberlanjutan lingkungan. Salah satu tantangan terbesar dalam pertanian adalah keberadaan gulma, yaitu tanaman pengganggu yang dapat menurunkan hasil panen secara signifikan. Gulma tidak hanya bersaing dengan tanaman utama dalam memperoleh nutrisi dan cahaya, tetapi juga dapat menyebarkan penyakit dan menghambat pertumbuhan tanaman secara umum [1]. Identifikasi gulma secara dini sangat penting dalam upaya pengendalian yang efektif. Metode tradisional seperti pengamatan manual memerlukan waktu yang lama, kurang efisien, dan rentan terhadap kesalahan manusia. Oleh karena itu, pendekatan berbasis teknologi kecerdasan buatan (*Artificial Intelligence / AI*) mulai banyak digunakan untuk mendeteksi dan mengklasifikasi gulma secara otomatis [2]. Salah satu teknologi yang berkembang pesat dalam bidang pengolahan citra adalah *Deep Learning*, khususnya arsitektur *Convolutional Neural Network (CNN)*. CNN mampu mengenali objek dalam gambar dengan sangat baik melalui proses ekstraksi fitur yang kompleks dan bertingkat [3].

GoogleNet adalah salah satu arsitektur CNN populer yang diperkenalkan oleh tim dari Google, dan dikenal dengan modul *Inception*-nya yang memungkinkan pemrosesan fitur multi-skala secara efisien [4]. Dalam penelitian sebelumnya, berbagai arsitektur CNN telah dibandingkan dalam klasifikasi citra gulma, termasuk GoogleNet, ShuffleNet, MobileNet, dan SqueezeNet. Meskipun GoogleNet menunjukkan performa terbaik, analisis mendalam terhadap satu arsitektur saja belum dilakukan secara khusus [5]. Salah satu implementasi AI yang telah banyak digunakan dalam pertanian adalah sistem berbasis *Computer Vision* dan *Deep Learning*. Menurut Eli-Chukwu (2019), teknologi AI memiliki potensi besar dalam mendeteksi kondisi pertanian termasuk klasifikasi tanaman dan gulma secara akurat, efisien, dan berkelanjutan [9]. Sementara itu, pendekatan berbasis CNN telah dibuktikan keunggulannya dalam berbagai studi. Salah satunya oleh Asad dan Bais (2020), yang berhasil menerapkan CNN untuk mendeteksi gulma pada lahan canola dengan hasil akurasi tinggi dan waktu klasifikasi yang cepat [10].

Studi serupa juga telah dilakukan oleh Altuntaş et al. (2019) yang berhasil mengidentifikasi benih jagung haploid dan diploid menggunakan pendekatan *transfer learning* pada arsitektur CNN dengan tingkat akurasi tinggi [11]. Namun, belum banyak penelitian yang secara khusus melakukan pendalaman terhadap satu arsitektur CNN saja dalam konteks klasifikasi gulma. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi secara menyeluruh kinerja arsitektur GoogleNet dalam klasifikasi citra gulma menggunakan pendekatan *transfer learning*. Fokus utama adalah pada penerapan fungsi optimasi Stochastic Gradient Descent with Momentum (SGDM) dan penilaian terhadap akurasi, *loss*, serta efisiensi waktu klasifikasi. Hasil dari studi ini diharapkan dapat menjadi acuan dalam pengembangan sistem klasifikasi gulma berbasis deep learning yang efisien dan akurat untuk diterapkan di lapangan.

2. METODE

2.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah DeepWeeds, yaitu kumpulan data citra gulma yang diambil dari sembilan lokasi berbeda di Australia. Dataset ini terdiri dari 17.509 gambar berwarna yang diklasifikasikan ke dalam sembilan kelas gulma, yaitu: *Chinee apple*, *Lantana*, *Parkinsonia*, *Parthenium*, *Pricky acacia*, *Rubber vine*, *Siam weed*, *Snake weed*, dan kelas *Another* [6]. Contoh gambar yang digunakan dapat dilihat pada Gambar 2, sedangkan jumlah gambar pada setiap kelas disajikan dalam Tabel 1 berikut. Dataset ini memiliki distribusi yang tidak merata antar kelas, di mana kelas *Another* memiliki jumlah gambar paling banyak. Dataset ini dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian. Untuk masing-masing arsitektur CNN yang digunakan dalam skema transfer learning, ukuran gambar diubah mengikuti ukuran input default dari arsitektur tersebut (dalam kasus GoogleNet: 224×224 piksel). Dataset DeepWeeds dipilih karena mencakup variasi luas jenis gulma dari sembilan lokasi berbeda di Australia sehingga representatif untuk tugas klasifikasi citra tanaman liar [6]. Ukuran gambar disesuaikan menjadi 224×224 piksel sesuai input default GoogleNet tanpa augmentasi guna menjaga distribusi asli data." "Pelatihan dilakukan menggunakan fungsi optimisasi SGDM dengan momentum $\mu=0,9$ dan laju belajar awal $\eta=0,001$ berdasarkan studi pendahuluan yang menunjukkan stabilitas konvergensi terbaik dibanding ADAM maupun RMSPROP.



Gambar 1. Contoh Dataset

Tabel 1. Dataset

Nama	Jumlah Gambar
Chinee apple	1.126
Lantana	1.064
Parkinsonia	1.031
Parthenium	1.024
Pricky acacia	1.062
Rubber vine	1.008
Siam weed	1.074
Snake weed	1.014
Another	9.106

2.2 Preprocessing

Setiap gambar dikonversi ukurannya menjadi 224×224 piksel agar sesuai dengan arsitektur input dari GoogleNet. Tidak dilakukan augmentasi, segmentasi, atau pengolahan tambahan lainnya. Semua gambar dipertahankan dalam format warna RGB dan tidak dikonversi ke grayscale. Dataset dibagi menjadi 80% data latih dan 20% data uji, tanpa menggunakan validasi silang, untuk menyederhanakan proses eksperimen.

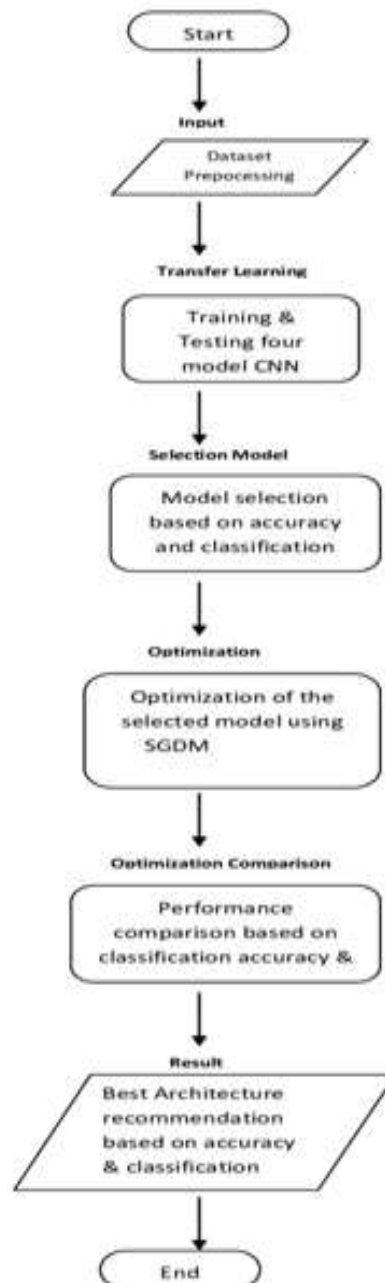
2.3 Transfer Learning pada GoogleNet

Model GoogleNet digunakan sebagai basis CNN karena arsitekturnya memiliki modul Inception yang dirancang untuk menangkap fitur dari berbagai ukuran kernel secara bersamaan, sehingga lebih

efisien secara komputasi dan lebih akurat dalam klasifikasi objek [7]. Pada proses transfer learning, seluruh layer awal GoogleNet dibekukan (*frozen layer*), dan hanya layer terakhir (*fully-connected layer*) yang diubah dan dilatih ulang agar menghasilkan output sebanyak sembilan kelas sesuai dataset.

2.4 Fungsi Optimasi

Untuk proses pelatihan, digunakan Stochastic Gradient Descent with Momentum (SGDM) sebagai fungsi optimasi. SGDM dipilih karena dalam eksperimen sebelumnya menunjukkan konvergensi yang stabil dan hasil akurasi tertinggi dibandingkan dengan fungsi optimasi lain seperti ADAM atau RMSPROP [8].

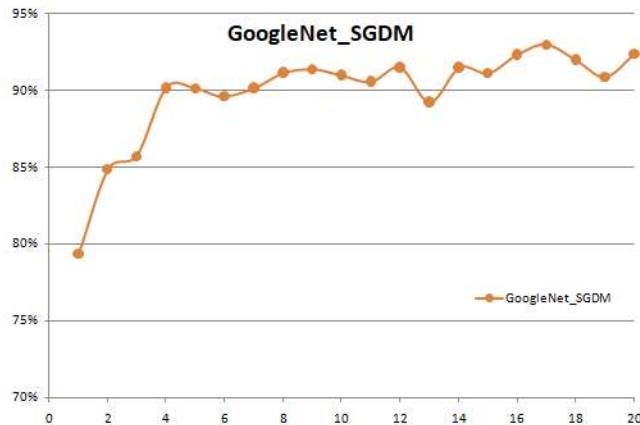


Gambar 2. Flowchart model

3. HASIL DAN PEMBAHASAN

3.1 Akurasi dan Loss

Model GoogleNet yang telah dimodifikasi melalui pendekatan *transfer learning* dilatih menggunakan fungsi optimasi SGDM. Hasil pelatihan menunjukkan bahwa model mencapai akurasi pelatihan sebesar 100% dan akurasi pengujian sebesar 92,38%. Nilai *loss* pada saat pelatihan adalah 0,0162, sedangkan pada data pengujian diperoleh nilai *loss* sebesar 0,4182. Nilai *loss* yang relatif rendah dan perbedaan yang tidak terlalu jauh antara *training loss* dan *testing loss* mengindikasikan bahwa model tidak mengalami *overfitting* secara signifikan. Hal ini menguatkan efektivitas pendekatan *transfer learning* pada arsitektur GoogleNet untuk tugas klasifikasi citra gulma.



Gambar 3. Hasil Training Dataset

Tabel 2. Hasil Akhir Performance

models	number of parameters	Accuracy (%)		Loss		classification time/Images(s)
		training	testing	training	testing	
GoogleNet	6,8 M	100	92,38%	0,0162	0,4182	0.0365

3.2 Analisis Kinerja Arsitektur

Struktur internal GoogleNet yang memanfaatkan Inception Module memungkinkan jaringan untuk mengekstraksi fitur dari gambar pada berbagai skala dalam satu proses. Ini menjadikan GoogleNet sangat adaptif dalam mengenali objek gulma yang memiliki bentuk dan tekstur berbeda-beda. Berdasarkan visualisasi hasil klasifikasi (*confusion matrix*), sebagian besar kelas dikenali dengan akurasi tinggi. Namun terdapat beberapa *false prediction* pada kelas yang memiliki kemiripan visual, seperti antara *Siam weed* dan *Snake weed*. Hal ini bisa menjadi bahan pertimbangan untuk pengembangan model klasifikasi bertingkat (*hierarchical classification*) atau penerapan teknik augmentasi selektif untuk kelas tertentu di masa depan. Secara umum, hasil penelitian ini mengonfirmasi bahwa GoogleNet dengan optimasi SGDM dapat dijadikan solusi efektif dan efisien dalam sistem klasifikasi gulma berbasis citra digital.

3.3 Analisis Performa Model

Hasil pengujian menunjukkan bahwa model GoogleNet yang dilatih dengan transfer learning dan fungsi optimasi SGDM mencapai akurasi sebesar 92,38% pada dataset DeepWeeds. Nilai *loss* pada set pengujian adalah 0.4182. Waktu klasifikasi rata-rata per gambar adalah 0.0365 detik. Hal ini menunjukkan performa yang baik dalam hal akurasi dan efisiensi waktu. Penggunaan transfer learning

terbukti efektif karena GoogleNet, yang awalnya dilatih pada dataset ImageNet yang besar dan beragam, mampu beradaptasi dengan baik pada dataset DeepWeeds yang lebih spesifik. Arsitektur GoogleNet yang dalam dan efisien dalam hal parameter, memungkinkan model untuk belajar fitur-fitur yang relevan dari citra gulma dengan cepat dan akurat, meskipun ukuran dataset DeepWeeds relatif lebih kecil dibandingkan ImageNet. Keunggulan ini sangat penting dalam konteks aplikasi pertanian presisi di mana waktu pemrosesan yang cepat sangat dibutuhkan.

3.4 Pembahasan

Penelitian ini menunjukkan bahwa arsitektur GoogleNet yang dimodifikasi melalui transfer learning dengan fungsi optimasi SGDM mampu mencapai akurasi pengujian sebesar 92,38% dan waktu klasifikasi rata-rata hanya 0,0365 detik per gambar. Nilai loss yang rendah pada data pelatihan (0,0162) dan pengujian (0,4182) mengindikasikan model memiliki kemampuan generalisasi yang baik tanpa overfitting signifikan.

Keunggulan GoogleNet terletak pada modul Inception-nya yang memungkinkan ekstraksi fitur multi-skala secara efisien sehingga sangat adaptif dalam mengenali berbagai jenis gulma dengan bentuk dan tekstur berbeda. Namun, analisis confusion matrix (yang akan ditambahkan di subbab 4.2) mengungkapkan adanya kesalahan prediksi terutama antara kelas gulma Siam weed dan Snake weed yang memiliki kemiripan visual tinggi. Hal ini membuka peluang untuk pengembangan model lebih lanjut seperti penerapan teknik augmentasi selektif atau klasifikasi bertingkat (hierarchical classification) guna meningkatkan akurasi khususnya pada kelas-kelas sulit dibedakan. Secara keseluruhan, hasil penelitian ini menegaskan efektivitas penggunaan transfer learning pada GoogleNet dengan optimasi SGDM sebagai solusi praktis dalam sistem klasifikasi citra gulma berbasis deep learning untuk mendukung pertanian presisi. Penelitian ini juga memberikan dasar kuat bagi implementasi teknologi serupa di perangkat mobile atau sistem real-time berbasis kamera drone di lapangan.

4. KESIMPULAN

Hasil evaluatif menunjukkan bahwa penggunaan transfer learning pada arsitektur GoogleNet bersama fungsi optimisasi SGDM efektif meningkatkan akurasi serta efisiensi waktu klasifikasi citra gulma hingga >90%. Temuan ini membuka peluang implementasinya dalam sistem pertanian cerdas real-time berbasis kamera drone maupun perangkat mobile guna mendukung praktik agronomi berkelanjutan. Berdasarkan hasil eksperimen, GoogleNet mampu mencapai akurasi pengujian sebesar 92,38% dengan waktu klasifikasi rata-rata 0,0365 detik per gambar. Stabilitas akurasi dan efisiensi waktu menunjukkan bahwa GoogleNet merupakan model yang efektif dan layak digunakan dalam sistem klasifikasi gulma berbasis citra digital, terutama untuk mendukung penerapan teknologi pertanian presisi. Penelitian ini memberikan landasan kuat untuk pengembangan lebih lanjut seperti implementasi pada perangkat mobile atau sistem real-time berbasis kamera dan drone.

REFERENSI

- [1] Z. Wu, Y. Chen, B. Zhao, X. Kang, and Y. Ding, "Review of weed detection methods based on computer vision," *Sensors*, vol. 21, no. 11, pp. 1–23, 2021.
- [2] C. Jiang, Q. Chang, and Z. G. Liu, "Weeds and Crops Classification Using Deep Convolutional Neural Network," *ACM Int. Conf. Proc. Ser.*, pp. 40–44, 2020.
- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436–444, May 2015.
- [4] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2015, pp. 1–9.

- [5] W. Syechu, B. B. Nasution, and M. S. Effendi, "Convolutional Neural Network Optimization for Deep Weeds," *Jurnal Dewantara: Ilmu Pengetahuan, Teknologi, dan Humaniora*, vol. 1, no. 1, pp. 1–7, Jun. 2023.
- [6] A. Olsen, D. A. Bright, M. D. Massaro, and N. A. Branson, "DeepWeeds: A Multiclass Weed Species Image Dataset for Deep Learning," *Sci. Data*, vol. 6, no. 1, pp. 1–9, 2019.
- [7] C. Szegedy et al., "Going Deeper with Convolutions," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2015, pp. 1–9.
- [8] E. M. Dogo, A. O. Adewale, O. O. Olugbara, and T. O. Folorunso, "Optimization Algorithms on Convolutional Neural Networks: A Comparative Review," in *Proc. Int. Conf. Comput. Technol. Electron. Mech. Syst. (CTEMS)*, 2018, pp. 92–99.
- [9] Eli-Chukwu, N. C. (2019). Applications of Artificial Intelligence in Agriculture: A Review. *Engineering, Technology & Applied Science Research*, 9(4), 4377–4383. <https://doi.org/10.48084/etasr.2756>
- [10] Asad, M. H., & Bais, A. (2020). Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), 535–545. <https://doi.org/10.1016/j.inpa.2019.12.002>
- [11] Altuntaş, Y., Cömert, Z., & Kocamaz, A. F. (2019). Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach. *Computers and Electronics in Agriculture*, 163(40), 1–11. <https://doi.org/10.1016/j.compag.2019.104874>