
PEMANFAATAN METODE CNN MENGGUNAKAN ARSITEKTUR ALEXNET UNTUK PENINGKATAN KINERJA KLASIFIKASI PENYAKIT DAUN TOMAT

Henry Bastian

Fakultas Ilmu Komputer, Program Studi Desain Komunikasi Visual
Universitas Dian Nuswantoro
Email: henry@dsn.dinus.ac.id

Ali Muqoddas

Fakultas Ilmu Komputer, Program Studi Desain Komunikasi Visual
Universitas Dian Nuswantoro
Email: alimuqoddas@dsn.dinus.ac.id

Dwi Puji Prabowo

Fakultas Ilmu Komputer, Program Studi Desain Komunikasi Visual
Universitas Dian Nuswantoro
Email: dwi.puji.prabowo@dsn.dinus.ac.id

Feri Agustina

Fakultas Ilmu Komputer, Program Studi Teknik Informatika
Universitas Dian Nuswantoro
Email: feri.agustina@dsn.dinus.ac.id

Ricardus Anggi Pramunendar

Fakultas Ilmu Komputer, Program Studi Teknik Informatika
Universitas Dian Nuswantoro
Email: ricardus.anggi@dsn.dinus.ac.id

ABSTRAK

Tomat adalah komoditas bernilai tinggi dalam hortikultura. Namun, kelemahan utamanya adalah rentan terhadap berbagai penyakit. Identifikasi visual penyakit pada daun tomat seringkali rumit dan sulit dipahami, yang dapat mengakibatkan asumsi yang tidak tepat tentang kondisi penyakitnya. Hal ini mengurangi efektivitas strategi pencegahan petani dan menyebabkan kerugian yang signifikan. Penelitian ini memperkenalkan pendekatan baru untuk identifikasi otomatis penyakit tomat menggunakan Convolutional Neural Network (CNN), dengan fokus pada evaluasi kinerja CNN menggunakan arsitektur AlexNet yang telah diatur khusus untuk mencari hasil optimal dari parameter yang digunakan. Analisis ini juga bertujuan untuk memahami hubungan antara parameter dan tingkat akurasi hasil, serta dampak dari pengaturan parameter pada dataset daun tomat dari PlantVillage. Hasil utama penelitian ini menunjukkan bahwa implementasi CNN dengan arsitektur AlexNet menghasilkan akurasi yang signifikan dalam identifikasi otomatis penyakit tomat. Penggunaan algoritma optimasi SGDM memberikan hasil terbaik dengan akurasi mencapai 96,413%, disusul oleh RMSProp dengan akurasi 94,472%, dan Adam dengan akurasi 91,191%. Hasil ini menunjukkan bahwa pemilihan algoritma optimasi yang tepat memengaruhi kinerja dan efisiensi proses identifikasi penyakit. Selain itu, analisis parameter juga memberikan wawasan penting tentang hubungannya dengan tingkat akurasi hasil, yang dapat membimbing penggunaan yang lebih efektif dari CNN dalam aplikasi identifikasi penyakit tanaman.

Kata kunci: Tomat, CNN, alexnet, parameter, optimasi

ABSTRACT

Tomatoes are known as one of the high-value commodities in horticulture. However, one of the main challenges faced by farmers is the vulnerability of tomatoes to various diseases. Visual identification of diseases on tomato leaves is often complex and difficult to understand at a glance, leading to inaccurate assumptions about the condition of the disease. Consequently, the prevention strategies implemented by farmers become less effective and result in significant losses. This study attempts to introduce a new approach to automatically identify tomato diseases using Convolutional Neural Network (CNN). This study focuses on evaluating the performance of CNN by implementing the AlexNet architecture that has been specifically configured to find the optimal results from the parameters used in the architecture. The analysis in this study is also aimed at understanding the relationship between the parameters used and the accuracy level of the results, as well as analyzing the impact of parameter settings on several tomato leaf datasets used from the PlantVillage dataset. The main results of this study indicate that the implementation of CNN with the AlexNet architecture produces significant accuracy in automatic identification of tomato diseases. The use of the SGDM optimization algorithm yielded the best results with an accuracy of 96.413%, followed by RMSProp with an accuracy of 94.472%, and Adam with an accuracy of 91.191%. These results indicate that the selection of the appropriate optimization algorithm affects the performance and efficiency of the disease identification process. Furthermore, the parameter analysis also provides important insights into its relationship with the accuracy level of the results, which can guide the more effective use of CNN in plant disease identification applications.

Keywords: *Tomatos, CNN, Alexnet, parameters, Optimization*

1. PENDAHULUAN

Mayoritas penduduk Indonesia bergantung pada pertanian sebagai mata pencaharian karena Indonesia merupakan negara agraris. Tanaman hortikultura, seperti tomat, tidak hanya berperan sebagai penyedia pangan melainkan juga menjadi sumber pendapatan ekonomi serta manfaat kesehatan bagi penduduk. Dikembangkan di Indonesia, tanaman hortikultura termasuk tomat diharapkan dapat memberikan peningkatan pendapatan bagi petani [1].

Tanaman tomat merupakan salah satu tanaman yang memiliki nilai ekonomi tinggi namun terdapat beberapa kendala dalam peningkatan kualitas hasil buahnya, hal ini disebabkan karena tanaman tomat merupakan tempa atau inang bagi pathogenic microorganisms yang berjumlah sekitar 200 Spesies dan perlu di penanganan serius [2]. Rotasi tanaman adalah tindakan yang efisien dan efektif dalam pencegahan penyakit pada tanaman tomat [3]. Tetapi berbeda kasus apabila tanaman tomat sudah terjangkit penyakit maka ahli biologilah yang nantinya akan menangani hal tersebut.

Dalam menanggulangi permasalahan penyakit daun tomat perlu strategi yang harus dilakukan. Langkah awal yang harus dilakukan adalah dengan cara mengidentifikasi penyakit sejak awal untuk mencegah terjadinya kerugian yang dialami oleh petani. Realitanya hal ini sulit dilakukan secara manual karena membutuhkan waktu yang cukup lama bila dilakukan secara manual oleh petani [4]. Selain itu deteksi secara manual terkadang hasil deteksi yang dilakukan bersifat bias [5]

Oleh karena pendeteksian penyakit pada tanaman tomat dapat dilakukan dengan menggunakan teknologi dengan melakukan prediksi secara otomatis, sehingga cara ini tidak akan menghabiskan waktu yang cukup lama bahkan akurasi yang dihasilkan cenderung lebih bagus dibandingkan dengan cara manual. Identifikasi yang dilakukan secara manual bahkan bisa berdampak merugikan bagi petani, karena identifikasi secara manual akan sangat sulit dilakukan dengan sekali pandang. Identifikasi secara manual berdasarkan dari indra visual manusia, sedangkan kemampuan indra manusia dalam mengenali secara visual berbeda-beda berdasarkan keterampilan, dan pengetahuan manusia tersebut [5], [6], sehingga kinerja identifikasi penyakit yang dihasilkan tidak akurat.

Kerjasama Pemerintah dengan para ahli biologi memegang peran penting dalam penanganan identifikasi penyakit pada tomat [7]. Hal ini merupakan motivasi yang mendasari metodologi yang diusulkan dengan bertujuan untuk mendeteksi dan mengklasifikasikan penyakit pada tanaman tomat secara akurat.

Deteksi penyakit tanaman secara otomatis telah dilakukan sebelumnya dengan menggunakan gambar mentah sebagai datasetnya [8]. Berbagai metode telah diajukan untuk klasifikasi dan deteksi penyakit daun tomat menggunakan teknik deep learning dan machine learning. Sebagai contoh, penelitian Attallah [9] merekomendasikan penggunaan K-nearest neighbor (KNN) dan support vector machine (SVM) yang berhasil mencapai akurasi tertinggi hingga 99,92% dan 99,90%, berturut-turut. Metode ini dikombinasikan dengan pendekatan seleksi fitur hibrida yang berhasil memilih fitur-fitur yang signifikan.

Jaringan saraf deep learning telah banyak digunakan oleh beberapa peneliti [10]–[16]. Metode deep learning digunakan untuk mengekstraksi fitur secara otomatis. Salah satu metode deep learning yang populer adalah convolutional neural network (CNN), yang merupakan jaringan saraf feed-forward multi-layer yang terdiri dari lapisan convolutional, aktivasi, pooling, dan fully connected. Sebagai contoh, Aggarwal [14] mengusulkan kerangka kerja deep learning yang mencapai akurasi 99,25% dalam mengklasifikasikan penyakit daun tomat, sementara Kibriya et al. [15] dan Zaki et al. [16] mengembangkan CNN dan MobileNet V2 untuk mendeteksi penyakit dengan akurasi lebih dari 94%. Sedangkan beberapa peneliti lain telah menggunakan berbagai arsitektur untuk mencapai tingkat akurasi yang tinggi. Perbandingan antara arsitektur Alexnet dan Googlenet dilakukan oleh Mohanty dkk menunjukkan Googlenet memiliki kinerja yang lebih baik dengan hasil sebesar 99,35% [17]. Perbandingan lain antara arsitektur Alexnet dan SqueezeNet dilakukan oleh Durmus dkk menunjukkan keunggulan Alexnet dengan akurasi 95,65% [10]. Di penelitian lain oleh Rangarajan dkk menyatakan bahwa Alexnet menunjukkan kinerja yang lebih baik dengan akurasi 97,49% dibandingkan dengan VGG16net [11].

Penelitian sebelumnya menunjukkan bahwa VGGNet memiliki kinerja terbaik pada 95,24%, berbeda dengan metode CNN sederhana berdasarkan arsitektur 2-layer dan arsitektur model lain seperti AlexNet, Googlenet. AlexNet dinilai mampu memberikan hasil klasifikasi yang lebih baik dalam beberapa penelitian. Namun, beberapa penelitian lain menemukan kinerja rendah karena penggunaan data yang kurang lengkap dan penentuan parameter yang tidak tepat. Oleh karena itu, penelitian ini difokuskan pada pengujian parameter metode CNN dengan arsitektur AlexNet menggunakan ukuran data yang telah ditentukan untuk meningkatkan akurasi kinerja secara keseluruhan [13]. Selain itu, penelitian juga dilakukan menggunakan data dari 14 spesies tanaman yang berasal dari dataset PlantVillage dengan total 54.306 gambar, menggunakan arsitektur Alexnet dengan akurasi mencapai 85,53% [17]. Beberapa penelitian menunjukkan keunggulan metode CNN dengan arsitektur AlexNet dibandingkan metode lain seperti Googlenet, SqueezeNet, VGG16net, VGGNet, dan CNN dual-layer [10], [11], [13].

Penelitian menunjukkan bahwa penggunaan CNN dengan arsitektur AlexNet memberikan kinerja yang lebih baik dibandingkan arsitektur lainnya karena penggunaan parameter yang tepat. Penelitian ini menguji setiap layer pada arsitektur AlexNet untuk menentukan layer yang memberikan kinerja terbaik. Kontribusi penelitian meliputi: (1) optimalisasi parameter untuk kinerja terbaik pada AlexNet, (2) analisis hubungan antara parameter dan akurasi, serta (3) analisis dampak parameter terhadap jumlah dataset, khususnya dataset PlantVillage.

2. METODOLOGI PENELITIAN

2.1 *Image Data*

Dalam penelitian ini, fokus utama adalah pada penyakit-penyakit yang umum ditemukan pada tanaman tomat, seperti bercak bakteri pada daun (bacterial leaf spot), blight (pembusukan) dini (early blight), blight (pembusukan) lanjut (late blight), cendawan lumut pada daun (leaf mold), bercak pada daun akibat jamur Septoria (septoria leaf spot), tungau laba-laba (spider mites), virus


kuning keriting daun (yellow leaf curl virus), dan virus mosaik (mosaic virus). Penelitian ini bertujuan untuk mengevaluasi efektivitas metode Convolutional Neural Network (CNN) berdasarkan arsitektur AlexNet dalam mengidentifikasi penyakit-penyakit tersebut.

Data yang digunakan terdiri dari 16.012 citra yang meliputi 10 kategori, yaitu 9 jenis penyakit tanaman dan 1 kategori untuk tanaman sehat. Citra-citra ini berasal dari dataset PlantVillage yang telah dilabeli secara manual oleh para ahli di bidang biologi dan pertanian. Setiap jenis penyakit dan kondisi sehat pada tanaman telah diberi label yang spesifik dan tervalidasi.

Penggunaan dataset yang komprehensif untuk menguji kinerja arsitektur AlexNet dalam melakukan klasifikasi penyakit tanaman tomat secara akurat. Hal ini penting untuk membantu petani dan praktisi pertanian dalam mengidentifikasi penyakit secara dini dan mengambil tindakan pencegahan yang tepat.

2.2 Convolutional Neural Network (CNN)

Arsitektur matematis parametrik pada CNN terdiri dari lapisan masukan, beberapa lapisan tersembunyi, dan lapisan keluaran [10]–[16]. Lapisan tersembunyi ini saling terhubung melalui serangkaian bobot, dengan setiap lapisan mewakili fitur yang lebih kompleks dari gambar masukan. CNN merupakan tumpukan modul multilayer sederhana, seperti lapisan konvolusi, lapisan *pooling*, dan lapisan *fully connected*. Dimulai dengan masukan citra, setiap modul dalam arsitektur ini secara bertahap mentransformasi representasi data dari satu level ke level yang lebih tinggi. Lapisan konvolusional menerapkan filter untuk mendeteksi fitur dasar, sementara lapisan aktivasi seperti ReLU memperkenalkan non-linearitas. Lapisan penggabungan mengurangi dimensi peta fitur dan membuat deteksi lebih robust terhadap perubahan posisi dan distorsi. Pada akhir jaringan, lapisan yang terhubung sepenuhnya menggabungkan semua fitur yang telah diekstraksi untuk membuat keputusan akhir atau klasifikasi, dengan lapisan keluaran memberikan hasil akhir seperti klasifikasi gambar atau prediksi. Dengan mentransformasi representasi data secara bertahap melalui lapisan-lapisan ini, CNN dapat mengenali dan mengklasifikasikan fitur yang semakin kompleks dalam gambar masukan.



Gambar 1. Ilustrasi CNN

Secara sistematis, alur kerja CNN dapat dijelaskan sebagai berikut:

1. Lapisan masukan menerima data gambar mentah sebagai masukan.
2. Lapisan konvolusional melakukan operasi konvolusi pada data masukan untuk mengekstraksi fitur-fitur yang relevan.
3. Lapisan penggabungan (pooling) melakukan operasi penyamplingan pada data keluaran lapisan konvolusional untuk mereduksi dimensi dan meningkatkan invariansi spasial.

4. Proses konvolusi dan penggabungan dapat diulang beberapa kali dengan lapisan-lapisan tersembunyi tambahan untuk mengekstraksi fitur yang lebih kompleks.
5. Lapisan yang terhubung sepenuhnya (*fully connected*) mengambil keluaran dari lapisan sebelumnya dan mengombinasikan semua fitur yang telah diekstraksi untuk menghasilkan keluaran akhir berupa skor klasifikasi atau prediksi.

Melalui proses ini, CNN dapat secara efektif belajar untuk mengekstraksi fitur-fitur penting dari data gambar dan melakukan tugas klasifikasi atau deteksi dengan akurasi yang tinggi. Ilustrasi CNN ditunjukkan pada Gambar 1.

2.3 Alexnet Architecture


AlexNet adalah arsitektur jaringan saraf konvolusional yang terdiri dari 5 lapisan konvolusional, diikuti oleh 3 lapisan yang terhubung sepenuhnya, dan diakhiri dengan lapisan softmax. Setelah lapisan konvolusional pertama dan kedua, terdapat lapisan normalisasi dan penggabungan untuk menstabilkan proses pelatihan dan mengurangi dimensi peta fitur. Lapisan konvolusional ketiga dan keempat tidak memiliki lapisan normalisasi atau penggabungan, sedangkan lapisan konvolusional kelima diikuti oleh satu lapisan penggabungan. Semua lapisan konvolusional di AlexNet menggunakan unit aktivasi non-linearitas ReLU, yang membantu jaringan belajar lebih cepat dan mengatasi masalah vanishing gradient. Dua lapisan yang terhubung sepenuhnya pertama memiliki lapisan dropout dengan rasio 0,5 untuk mencegah overfitting, sementara lapisan terakhir yang terhubung sepenuhnya memiliki keluaran sesuai dengan jumlah kelas dalam dataset. Di ujung arsitektur, lapisan softmax mengubah skor keluaran menjadi probabilitas dengan melakukan normalisasi eksponensial, menghasilkan distribusi probabilitas yang totalnya berjumlah 1. Probabilitas ini menunjukkan tingkat kepercayaan jaringan bahwa gambar masukan termasuk dalam setiap kelas. Dengan struktur ini, AlexNet mampu menangkap berbagai tingkat fitur dari gambar masukan, mulai dari fitur dasar seperti tepi dan tekstur pada lapisan konvolusional awal, hingga fitur yang lebih kompleks dan abstrak pada lapisan yang lebih dalam, memungkinkan jaringan untuk secara efektif mengklasifikasikan gambar dengan tingkat akurasi yang tinggi.

2.4 CNN berbasis minimal data

CNN memiliki jutaan koneksi dan bobot, serta memanfaatkan koneksi lokal dan bobot bersama untuk mengurangi jumlah bobot yang perlu dilatih, masih terdapat risiko overfitting terutama saat bekerja dengan ukuran sampel kecil. Overfitting terjadi ketika CNN menunjukkan akurasi tinggi pada set pelatihan tetapi performa buruk pada set pengujian. Oleh karena itu, kami mengusulkan solusi untuk mengenali jenis penyakit daun tomat dengan ukuran sampel kecil.

Proses pengenalan penyakit daun ini dibagi menjadi beberapa tahap. Pada tahap pertama, CNN dilatih menggunakan kumpulan data gambar yang besar. Berbagai pengaturan lapisan digunakan dalam tahap ini untuk mencapai kinerja terbaik. CNN tidak hanya berfungsi sebagai pengklasifikasi tetapi juga sebagai ekstraktor fitur, di mana lapisan tersembunyi belajar merepresentasikan masukan sedemikian rupa sehingga prediksi keluaran menjadi lebih mudah. Setelah pelatihan selesai, CNN yang sudah dilatih akan peka terhadap informasi seperti warna, tekstur, dan tepi gambar.

Tahap selanjutnya adalah menguji kinerja CNN yang telah dilatih. Sumber data dan pengaturan parameter sangat penting untuk mencapai akurasi terbaik. Teknik ini diterapkan pada dataset PlantVillage yang terdiri dari 16.011 citra, mencakup 10 jenis penyakit tanaman. Dataset ini dibagi menjadi data pelatihan (12.809 citra) dan data pengujian (3.202 citra), dengan segmentasi yang dilakukan untuk mendapatkan citra daun yang bersih dari latar belakang yang berbeda. Dalam penerapan CNN, arsitektur AlexNet digunakan dengan berbagai pengaturan lapisan dan filter. Proses iterasi dilakukan sebanyak 10 kali untuk setiap percobaan guna memastikan konsistensi hasil.



Gambar 2 . Visualisasi Layer

2.5 Evaluasi

Penilaian kinerja metode klasifikasi dilakukan melalui penggunaan akurasi. Akurasi diartikan sebagai proporsi dari seluruh data yang diklasifikasikan secara tepat. Rumus untuk menghitung akurasi, seperti yang dinyatakan dalam Persamaan (1), mempertimbangkan jumlah data yang diklasifikasikan secara benar oleh para ahli, yang dilambangkan sebagai t , dibagi dengan jumlah total data sampel, yang dilambangkan sebagai n .

Dalam konteks ini, akurasi menjadi indikator penting yang mengukur kemampuan model klasifikasi dalam mengenali kategori yang benar untuk data yang diberikan. Dengan menggunakan rumus akurasi, evaluasi dapat dilakukan untuk menilai sejauh mana model mampu memprediksi kategori yang tepat. Akurasi yang tinggi menggambarkan keandalan model dalam melakukan klasifikasi yang tepat, sementara akurasi yang rendah mengindikasikan kinerja yang kurang optimal dan mungkin memerlukan peningkatan atau penyesuaian lebih lanjut.

$$accuracy = \frac{t}{n} \times 100 \quad (1)$$


3. HASIL DAN PEMBAHASAN

Pada percobaan serta evaluasi setiap parameter dalam struktur AlexNet, penggunaan masing-masing lapisan divisualisasikan seperti yang ditunjukkan dalam Gambar 2. Visualisasi layer-layer ini dianalisis secara terpisah untuk setiap iterasi, dan hasilnya dijelaskan secara detail dalam bagian ini.


3.1 Evaluasi Layer

Pada tahap awal eksperimen, digunakan konfigurasi yang melibatkan input layer untuk gambar dengan ukuran 256 x 256 piksel dan 3 channel warna (RGB). Proses konvolusi dilakukan menggunakan `convolution2dLayer` dengan penerapan delapan filter, stride sebesar 3 x 3, dan padding 'same' untuk memastikan minimnya kehilangan fitur dengan menambahkan angka 0 di sekeliling matriks. Bobot awal diinisialisasi dengan nilai default sesuai dengan fungsi yang tersedia. Untuk normalisasi aktivasi dan gradien yang melewati jaringan, digunakan `batchNormalizationLayer`, sementara `reluLayer` digunakan untuk mengubah nilai data yang kurang dari 0 menjadi 0. `maxPooling2dLayer` digunakan untuk melakukan operasi pooling dengan ukuran stride 2. Proses ini diiterasikan hingga mencapai lapisan kelima dengan ukuran filter yang telah

ditentukan. Selanjutnya, fullyConnectedLayer diterapkan sesuai dengan jumlah kelas, diikuti dengan restrukturisasi feature map menjadi vektor yang digunakan sebagai input pada lapisan tersebut. Hasil dari percobaan awal menunjukkan fluktuasi penurunan akurasi pengujian data dari epoch 3, yang kemudian diikuti dengan peningkatan pada epoch 9. Total waktu yang diperlukan untuk pelatihan adalah 2039 detik, dengan akurasi kinerja mencapai 72,36%.




(i)




(ii)




(iii)




(iv)




(v)




(vi)



(vii)



(viii)



(ix)

Gambar 3. Grafik Hasil Pengujian

Sembilan percobaan tersebut dirangkum dalam Tabel 1 yang memberikan hasil kinerja setiap konfigurasi percobaan. Percobaan melibatkan berbagai konfigurasi layer konvolusi dengan filter yang berbeda dan inisialisasi bobot untuk menentukan pengaruhnya terhadap waktu pelatihan dan akurasi model.

Tabel 1. Hasil Percobaan

No	Layer	Waktu (s)	Akurasi %
1	1 layer konvolusi, 8 filter, 1 layer konvolusi	2039	72,361
2	1 layer konvolusi, 8 filter, Inisialisasi He, 1 layer konvolusi	2076	84,623
3	2 layer konvolusi, 8,16 filter, Inisialisasi He, 1 layer konvolusi	2922	87,952
4	3 layer konvolusi, 8, 16, 32 filter, Inisialisasi He, 1 layer konvolusi	3324	92,353
5	4 layer konvolusi, 8, 16, 32, 64 filter, Inisialisasi He, 1 layer konvolusi	3467	93,191
6	4 layer konvolusi, 8, 16, 32, 64 filter, Inisialisasi Glorot, 1 layer konvolusi	3491	94,691
7	5 layer konvolusi, 8, 16, 32, 64, 128 filter, He Glorot, 1 layer konvolusi	2039	95,224
8	6 layer konvolusi, 8, 16, 32, 64, 128, 256 filter, He Glorot, 1 layer konvolusi	2076	95,823
9	6 layer konvolusi, 8, 16, 32, 64, 128, 256, 256 filter, Inisialisasi Glorot, 1 layer konvolusi	2922	96,411

Pada konfigurasi pertama, digunakan satu layer konvolusi dengan delapan filter dan satu layer konvolusi tambahan tanpa inisialisasi bobot khusus. Hasilnya, model mencapai akurasi sebesar 72,361% dengan waktu pelatihan 2039 detik. Pada konfigurasi kedua, dengan tetap menggunakan satu layer konvolusi dengan delapan filter tetapi menambahkan inisialisasi bobot He, akurasi meningkat menjadi 84,623% dengan waktu pelatihan sedikit lebih lama, yaitu 2076 detik. Selanjutnya, konfigurasi ketiga melibatkan dua layer konvolusi dengan delapan dan enam belas filter serta inisialisasi bobot He, menghasilkan akurasi yang lebih baik yaitu 87,952% namun dengan waktu pelatihan yang lebih panjang, 2922 detik.

Ketika tiga layer konvolusi digunakan pada konfigurasi keempat dengan filter bertambah secara bertahap menjadi delapan, enam belas, dan tiga puluh dua, serta menggunakan inisialisasi He, akurasi melonjak menjadi 92,353% dengan waktu pelatihan 3324 detik. Penambahan layer keempat dengan filter bertambah hingga enam puluh empat pada konfigurasi kelima, masih dengan inisialisasi He, lebih meningkatkan akurasi hingga 93,191% dengan waktu pelatihan 3467 detik. Pada konfigurasi keenam, meskipun menggunakan empat layer konvolusi yang sama dengan inisialisasi Glorot, akurasi lebih lanjut meningkat menjadi 94,691% dalam waktu 3491 detik.

Konfigurasi ketujuh memperkenalkan lima layer konvolusi dengan filter bertambah hingga seratus dua puluh delapan, menggunakan inisialisasi He Glorot, dan mencapai akurasi 95,224% dalam 2039 detik. Konfigurasi kedelapan menambahkan layer keenam dengan filter dua ratus lima puluh enam, yang secara signifikan meningkatkan akurasi hingga 95,823% dengan waktu pelatihan 2076 detik. Akhirnya, konfigurasi kesembilan menambahkan satu layer konvolusi lagi dengan dua filter dua ratus lima puluh enam, menggunakan inisialisasi Glorot, yang menghasilkan akurasi tertinggi sebesar 96,411% dengan waktu pelatihan terpanjang yaitu 2922 detik.


Dari hasil ini, terlihat bahwa peningkatan jumlah layer konvolusi dan penggunaan inisialisasi bobot yang lebih baik secara signifikan meningkatkan akurasi model. Meskipun waktu pelatihan juga meningkat seiring dengan kompleksitas model, konfigurasi dengan enam layer konvolusi dan filter yang bertambah, serta menggunakan inisialisasi Glorot, memberikan hasil akurasi terbaik sebesar 96,411%. Hasil menunjukkan bahwa semakin banyak layer yang digunakan, kinerja model semakin baik.

3.2 Evaluasi setiap Parameter Training Network

Pada tahap ini, dilakukan serangkaian percobaan untuk menguji setiap tahap pelatihan jaringan menggunakan tiga jenis algoritma optimasi yang berbeda: SGDM (Stochastic Gradient Descent with Momentum), RMSProp, dan Adam. Tujuan dari pengujian ini adalah untuk mengevaluasi dan


membandingkan kinerja masing-masing algoritma optimasi dalam konteks pengenalan jenis penyakit daun pada dataset yang digunakan.

Penggunaan algoritma SGDM (Gambar 4) menunjukkan peningkatan kinerja yang signifikan, terutama terlihat pada epoch ke-5. Proses pelatihan dengan SGDM diselesaikan dalam waktu 4314 detik untuk menyelesaikan 10 epoch, dengan mencapai akurasi sebesar 96,413%. Hasil ini menunjukkan bahwa SGDM efektif dalam mengoptimalkan jaringan, yang tercermin dalam peningkatan akurasi seiring berjalannya epoch.




Gambar 4. Percobaan optimasi *sgdm*

Pada percobaan dengan algoritma RMSProp (Gambar 5), meskipun hasilnya juga cukup baik dengan akurasi 94,472%, waktu yang dibutuhkan untuk menyelesaikan 10 epoch sedikit lebih lama, yakni 4338 detik. Ini menunjukkan bahwa RMSProp juga mampu memberikan hasil yang memuaskan, meskipun dengan kecepatan konvergensi yang sedikit lebih lambat dibandingkan dengan SGDM.



Gambar 5. Percobaan optimasi *rmsprop*

Selanjutnya, percobaan dengan algoritma Adam (Gambar 6) menunjukkan hasil yang sedikit lebih rendah, dengan akurasi 91,191%, dan waktu pelatihan yang lebih lama, yakni 4601 detik untuk menyelesaikan 10 epoch. Meskipun Adam dikenal sebagai algoritma yang adaptif dan cepat konvergen, dalam konteks ini, hasilnya menunjukkan bahwa Adam memerlukan waktu pelatihan yang lebih lama dan menghasilkan akurasi yang lebih rendah dibandingkan dengan SGDM dan RMSProp.



Gambar 6. Percobaan optimasi *adam*

Dari ketiga optimasi training yang diuji, hasil terbaik diperoleh menggunakan SGDM dengan akurasi 96,411%. Hal ini menunjukkan bahwa SGDM adalah metode optimasi yang paling efektif dalam konteks pengenalan jenis penyakit daun pada dataset yang digunakan. Percobaan ini juga memberikan wawasan penting bahwa pemilihan algoritma optimasi yang tepat dapat sangat memengaruhi kinerja dan efisiensi proses pelatihan jaringan neural. Dalam konteks aplikasi praktis,

penggunaan algoritma optimasi yang sesuai dapat menghasilkan peningkatan akurasi yang signifikan dan mempercepat konvergensi model, yang secara keseluruhan dapat meningkatkan kualitas dan efisiensi sistem pengenalan penyakit daun.

4. KESIMPULAN

Penelitian ini menganalisis hubungan antara parameter yang digunakan dan kinerja akurasi dalam penggunaan Convolutional Neural Network (CNN) dengan arsitektur AlexNet. Hasil penelitian menunjukkan bahwa penggunaan stochastic gradient descent with momentum (SGDM) memberikan kinerja terbaik dengan waktu penyelesaian yang paling singkat dibandingkan dengan RMSProp dan Adam. Penggunaan lebih banyak layer dalam implementasi metode CNN dengan arsitektur AlexNet menyebabkan peningkatan kinerja, tetapi juga memperpanjang waktu proses. Namun, hasil penelitian menunjukkan bahwa penambahan layer dapat meningkatkan akurasi secara signifikan, meskipun membutuhkan waktu komputasi yang lebih lama. Oleh karena itu, dalam penerapan praktis, pemilihan jumlah layer harus dipertimbangkan dengan baik untuk mencapai keseimbangan antara akurasi dan waktu komputasi yang diperlukan.

DAFTAR PUSTAKA

- [1] E. C. Miller, C. W. Hadley, S. J. Schwartz, J. W. Erdman, T. W. M. Boileau, and S. K. Clinton, "Lycopene, tomato products, and prostate cancer prevention. Have we established causality?," *Pure and Applied Chemistry*, vol. 74, no. 8, pp. 1435–1441, 2002, doi: 10.1351/pac200274081435.
- [2] M. J. Stout, H. Kurabchew, and G. L. D. Leite, *Host-Plant Resistance in Tomato*. Elsevier Inc., 2017. doi: 10.1016/B978-0-12-802441-6.00009-7.
- [3] E. A. Curl, "Control Of Plant Diseases By Crop Rotation," *The Botanical Review*, vol. 29, no. 4, 1963, doi: sci-hub.tw/10.2307/4353677.
- [4] P. Tm, A. Pranathi, K. Sai Ashritha, N. B. Chittaragi, and S. G. Koolagudi, "Tomato Leaf Disease Detection Using Convolutional Neural Networks," in *2018 Eleventh International Conference on Contemporary Computing (IC3)*, IEEE, Aug. 2018, pp. 1–5. doi: 10.1109/IC3.2018.8530532.
- [5] R. A. Pramunendar, S. Wibirama, P. I. Santosa, P. N. Andono, and M. A. Soeleman, "A robust image enhancement techniques for underwater fish classification in marine environment," *International Journal of Intelligent Engineering and Systems*, vol. 12, no. 5, pp. 116–129, 2019, doi: 10.22266/ijies2019.1031.12.
- [6] Y. Sari, P. B. Prakoso, and A. R. Baskara, "Application of neural network method for road crack detection," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 18, no. 4, pp. 1962–1967, 2020, doi: 10.12928/TELKOMNIKA.V18I4.14825.
- [7] N. A. Rose and E. C. M. Parsons, "'Back off, man, I'm a scientist!' When marine conservation science meets policy," *Ocean and Coastal Management*, vol. 115, pp. 71–76, 2015, doi: 10.1016/j.ocecoaman.2015.04.016.
- [8] E. E. Lavindi, E. J. Kusuma, G. F. Shidik, R. A. Pramunendar, A. Z. Fanani, and Pujiono, "Neural Network based on GLCM, and CIE L*a*b* Color Space to Classify Tomatoes

-
- Maturity,” in 2019 International Seminar on Application for Technology of Information and Communication (iSemantic), 2019, pp. 1–6. doi: 10.1109/ISEMANTIC.2019.8884307.
- [9] O. Attallah, “Tomato Leaf Disease Classification via Compact Convolutional Neural Networks with Transfer Learning and Feature Selection,” *Horticulturae*, vol. 9, no. 2, 2023, doi: 10.3390/horticulturae9020149.
- [10] H. Durmus, E. O. Gunes, and M. Kirci, “Disease detection on the leaves of the tomato plants by using deep learning,” 2017 6th International Conference on Agro-Geoinformatics, *Agro-Geoinformatics 2017*, 2017, doi: 10.1109/Agro-Geoinformatics.2017.8047016.
- [11] A. K. Rangarajan, R. Purushothaman, and A. Ramesh, “Tomato crop disease classification using pre-trained deep learning algorithm,” *Procedia Computer Science*, vol. 133, pp. 1040–1047, 2018, doi: 10.1016/j.procs.2018.07.070.
- [12] M. Sardogan, A. Tuncer, and Y. Ozen, “Plant Leaf Disease Detection and Classification Based on CNN with LVQ Algorithm,” *UBMK 2018 - 3rd International Conference on Computer Science and Engineering*, pp. 382–385, 2018, doi: 10.1109/UBMK.2018.8566635.
- [13] E. Suryawati, R. Sustika, R. S. Yuwana, A. Subekti, and H. F. Pardede, “Deep structured convolutional neural network for tomato diseases detection,” 2018 International Conference on Advanced Computer Science and Information Systems, *ICACSIS 2018*, pp. 385–390, 2019, doi: 10.1109/ICACSIS.2018.8618169.
- [14] A. K. Aggarwal, “Biological Tomato Leaf Disease Classification using Deep Learning Framework,” *International Journal of Biology and Biomedical Engineering*, vol. 16, pp. 241–244, 2022, doi: 10.46300/91011.2022.16.30.
- [15] H. Kibriya, R. Rafique, W. Ahmad, and S. M. Adnan, “Tomato Leaf Disease Detection Using Convolution Neural Network,” *Proceedings of 18th International Bhurban Conference on Applied Sciences and Technologies, IBCAST 2021*, pp. 346–351, 2021, doi: 10.1109/IBCAST51254.2021.9393311.
- [16] S. Z. M. Zaki, M. A. Zulkifley, M. Mohd Stofa, N. A. M. Kamari, and N. A. Mohamed, “Classification of tomato leaf diseases using mobilenet v2,” *IAES International Journal of Artificial Intelligence*, vol. 9, no. 2, pp. 290–296, 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [17] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *Frontiers in Plant Science*, vol. 7, no. September, pp. 1–10, 2016, doi: 10.3389/fpls.2016.01419.