

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK DALAM MENENTUKAN TINGKAT KEMATANGAN MENTIMUN DAN TOMAT BERDASARKAN WARNA KULIT

Alifah Maya Kinanti Putri, Anief Fauzan Rozi

Sistem Informasi, Universitas Mercu Buana Yogyakarta
Jl. Jembatan Merah No. 84C Gejayan, Yogyakarta, Indonesia
201110065@student.mercubuana-yogya.ac.id

ABSTRAK

Penentuan tingkat kematangan mentimun dan tomat sangat penting untuk memastikan kualitas produk yang sampai ke konsumen. proses ini sering dilakukan secara manual, yang cenderung kurang akurat dan memakan waktu lama. Keterbatasan ini dapat menyebabkan distribusi buah yang belum matang atau busuk, yang pada akhirnya berdampak pada kerugian bagi petani dan distributor serta menurunkan kepuasan konsumen. Dalam era pertanian modern, diperlukan solusi yang lebih efisien dan akurat untuk mengatasi masalah ini. Penelitian ini bertujuan untuk mengembangkan model berbasis *Convolutional Neural Network* (CNN) yang dapat mengklasifikasikan kematangan mentimun dan tomat berdasarkan warna kulitnya. Dengan menggunakan dataset yang terdiri dari 2779 citra dan pembagian menjadi empat kelas (mentimun matang, mentimun busuk, tomat matang, dan tomat busuk), penelitian ini mengimplementasikan model CNN dalam MATLAB. Hasil penelitian menunjukkan bahwa model CNN dengan optimizer Adam mampu mencapai akurasi hingga 97% dan nilai loss terendah 3%. Solusi ini diharapkan dapat membantu petani dan distributor dalam menentukan kematangan buah secara lebih cepat dan akurat, mengurangi kerugian, dan meningkatkan kualitas produk yang diterima oleh konsumen.

Kata kunci : *Mentimun, tomat, pengolahan citra digital, Convolutional Neural Network (CNN), akurasi klasifikasi*

1. PENDAHULUAN

Mentimun adalah salah satu sayuran yang sangat populer di Indonesia. Selain kaya akan air dan nutrisi, mentimun sering dijadikan bahan dalam berbagai hidangan, mulai dari salad, acar, hingga minuman segar. Kualitas mentimun sangat tergantung pada tingkat kematangannya. Mentimun yang segar punya tekstur renyah dan rasa yang enak, sementara mentimun yang terlalu matang atau busuk tidak hanya kehilangan rasa, tapi juga bisa berbahaya bagi kesehatan[1].

Tomat merupakan salah satu buah yang memiliki tingkat kematangan tertentu dalam kurun waktu yang singkat[13]. U

ntuk menentukan kematangan buah tomat tidak hanya dapat dilakukan secara manual. Tomat memiliki warna hijau sebagai warna buah yang belum matang dan orange, merah sebagai warna buah tomat yang sudah matang dan bisa dimakan dengan berbagai cara[14].

Di dunia pertanian, menentukan kematangan mentimun biasanya dilakukan secara manual, mengandalkan ketelitian dan pengalaman seseorang. Sayangnya, cara manual ini tidak selalu akurat dan konsisten, serta memakan waktu lama. Karena itu, dibutuhkan teknologi yang bisa membantu menentukan kematangan dengan cepat, akurat, dan konsisten. Salah satu teknologi yang berkembang pesat untuk ini adalah pengolahan citra digital dan pembelajaran mesin (*machine learning*)[2].

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data bergambar. CNN mampu mengekstrak fitur-fitur penting dari gambar melalui beberapa lapisan *konvolusi*, *pooling*, dan *fully connected*. Dalam konteks menentukan kematangan mentimun, CNN bisa digunakan untuk menganalisis warna kulit mentimun dan tomat lalu mengklasifikasikannya sebagai *fresh* atau *rotten*. Dengan menggunakan teknik ini, proses klasifikasi diharapkan menjadi lebih cepat dan akurat dibandingkan cara manual[3].

Penelitian ini fokus pada beberapa pertanyaan utama, yaitu bagaimana CNN dapat membedakan antara citra buah matang dan buruk berdasarkan warna kulitnya, serta seberapa akurat CNN dalam mengklasifikasikan tingkat kematangan mentimun dan tomat. Tujuannya adalah mengembangkan model CNN yang mampu mengklasifikasikan tingkat kematangan citra berdasarkan warna kulitnya, mengimplementasikan model CNN tersebut menggunakan MATLAB, serta mengevaluasi kinerjanya dalam klasifikasi mentimun matang dan busuk, dan membandingkannya dengan metode konvensional[4].

Penelitian ini diharapkan memberikan manfaat praktis dan akademis, seperti menyediakan alat bantu yang efektif bagi petani dan distributor dalam menentukan tingkat kematangan mentimun dan tomat, mengurangi kerugian akibat distribusi buah yang tidak layak konsumsi, meningkatkan kualitas

produk mentimun dan tomat yang sampai ke konsumen, dan menambah pengetahuan baru dalam penerapan teknologi CNN untuk klasifikasi produk pertanian[5].

Namun, penelitian ini juga memiliki beberapa batasan. Dataset yang digunakan mencakup gambar citra matang dan busuk yang diambil dalam kondisi pencahayaan seragam. Penentuan kematangan hanya didasarkan pada warna kulit, tanpa mempertimbangkan faktor lain seperti tekstur atau ukuran. Implementasi dilakukan menggunakan MATLAB, sehingga hasilnya mungkin tidak langsung dapat diintegrasikan dengan sistem lain yang menggunakan platform berbeda [3].

Dengan memahami latar belakang, konsep dasar, rumusan masalah, tujuan, manfaat, dan batasan penelitian ini, diharapkan dapat memberikan gambaran yang jelas tentang pentingnya teknologi CNN dalam menentukan tingkat kematangan citra dan langkah-langkah yang diambil untuk mencapai tujuan penelitian ini.

2. TINJAUAN PUSTAKA

2.1. Pengolahan Citra Digital dalam Pertanian

Pengolahan citra digital adalah teknik yang semakin populer dalam pertanian, khususnya untuk menganalisis kualitas tanaman. Teknologi ini memungkinkan kita untuk melakukan analisis visual secara lebih akurat dan efisien dibandingkan metode manual. Misalnya, pengolahan citra digital bisa digunakan untuk mengevaluasi warna, tekstur, dan bentuk buah atau sayuran, yang sangat penting untuk menentukan kematangan. Penelitian menunjukkan bahwa teknik ini efektif dalam mengidentifikasi dan mengklasifikasikan berbagai jenis buah berdasarkan kematangan mereka. Hal ini menunjukkan bahwa teknologi ini bisa juga diterapkan pada mentimun untuk menilai kualitasnya dengan lebih cepat dan tepat[2].

2.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data bergambar. CNN bekerja dengan lapisan-lapisan yang masing-masing berfungsi untuk mengekstrak fitur-fitur penting dari gambar, seperti pola dan tekstur. Penelitian telah menunjukkan bahwa CNN sangat efektif dalam mengklasifikasikan gambar dan mendeteksi objek, bahkan dalam konteks yang kompleks. Dengan kemampuannya untuk belajar dari data gambar, CNN dapat digunakan untuk mengidentifikasi berbagai kondisi dan kategori, termasuk dalam aplikasi pertanian seperti menentukan kematangan buah mentimun dan tomat.

2.3. Implementasi CNN dalam Klasifikasi Buah

Menggunakan CNN untuk mengklasifikasikan buah mentimun dan tomat telah menunjukkan hasil yang positif. Penelitian sebelumnya menunjukkan

bahwa CNN dapat dengan akurat mengklasifikasikan buah berdasarkan kondisi mereka, seperti segar atau busuk. Model CNN telah berhasil digunakan untuk berbagai jenis buah, membuktikan bahwa teknologi ini dapat diterapkan juga pada buah mentimun dan tomat. CNN dapat mengenali pola warna dan tekstur yang berbeda, yang sangat membantu dalam menentukan apakah mentimun masih segar atau sudah mulai membusuk[7].

2.4. MATLAB sebagai Platform Pengembangan CNN

MATLAB adalah perangkat lunak yang banyak digunakan dalam penelitian dan pengembangan teknologi, termasuk pengolahan citra dan pembelajaran mesin. MATLAB menyediakan berbagai alat dan fungsi untuk merancang dan melatih model CNN. Dengan *toolbox* khusus untuk *deep learning*, MATLAB memudahkan pengguna untuk mengembangkan model CNN secara efisien. Penelitian menunjukkan bahwa MATLAB sangat efektif dalam mengimplementasikan model CNN, memungkinkan analisis yang mendalam dan pengujian yang akurat[8].

2.5. Studi Kasus: Klasifikasi Kematangan Buah

Ada beberapa studi yang telah menggunakan CNN untuk mengklasifikasikan kematangan buah. Misalnya, ada penelitian yang menggunakan CNN untuk mendeteksi tingkat kematangan tomat. Hasilnya menunjukkan bahwa CNN dapat mengidentifikasi kematangan dengan tingkat akurasi yang tinggi. Ini membuktikan bahwa teknik yang sama bisa diterapkan pada mentimun untuk klasifikasi kematangan berdasarkan warna kulit[9].

3. METODE PENELITIAN


Studi ini memanfaatkan metode *Convolutional Neural Network* (CNN) untuk mengklasifikasikan gambar mentimun dan tomat berdasarkan tingkat kematangan kulitnya. Pada tahap awal penelitian, data dikumpulkan untuk digunakan sebagai instruksi, validasi, dan input. Kemudian, metode CNN diterapkan untuk merancang jaringan yang dapat menganalisis gambar mentimun[10].

CNN digunakan untuk melatih model dengan data pelatihan yang telah dikumpulkan. Melalui pelatihan ini, model diharapkan dapat membedakan buah yang segar dari yang busuk dengan akurasi yang tinggi. Setelah pelatihan, data diuji untuk memastikan keakuratan dan validitas hasil klasifikasi. Hasil uji menunjukkan bahwa model CNN dapat dengan baik membedakan antara buah segar dan busuk, membuktikan efektivitas teknik ini dalam mengidentifikasi tingkat kematangan buah mentimun dan tomat[11].

3.1. Alur Penelitian

Penelitian ini mempunyai 6 tahap, dimulai dengan akuisisi citra buah Matang dan Busuk hingga

hasil akurasi dalam membedakan cabai sehat atau terinfeksi antraknosa. Alur penelitian ditunjukkan pada Gambar 1[12].



Gambar 1. Alur Tahap Penelitian

3.2. Akuisisi Citra

Dalam penelitian ini, akuisisi citra mentimun dan tomat dilakukan dengan menggunakan dataset yang tersedia di platform Kaggle. Kaggle merupakan salah satu platform terkemuka yang menyediakan berbagai dataset untuk keperluan penelitian dan pengembangan di bidang data science dan machine learning. Dataset yang digunakan dalam penelitian ini terdiri dari gambar-gambar buah mentimun dan tomat yang diambil dalam berbagai kondisi kematangan dan pencahayaan. Sebanyak 1000 gambar Data dibagi menjadi dua kelas yaitu 1.530 gambar mentimun terdiri dari 768 gambar Mentimun Matang, 762 gambar Mentimun Busuk dan 1.249 gambar tomat yang terdiri dari 654 gambar Tomat Matang, 595 gambat Tomat Busuk.

3.3. Pelabelan citra

Setelah citra cabai diakuisisi, tahap berikutnya adalah pelabelan citra. Citra yang terkumpul kemudian dikategorikan menjadi dua kelompok yaitu mentimun matang dan busuk, tomat matang dan busuk. Proses pelabelan ini dilakukan secara manual.

Tabel 1. Citra Mentimun


No	Kelas	Citra Mentimun	Jumlah
1	Matang		768
2	Busuk		762

Tabel 2. Citra Tomat

No	Kelas	Citra Tomat	Jumlah
1	Matang		654
2	Busuk		595

3.4. Resize

Resize adalah tahap penting memastikan ukuran konsisten dari gambar input, meningkatkan efisiensi komputasi, dan memungkinkan model untuk mempelajari fitur yang lebih umum. Dengan menggunakan teknik resize yang tepat, dapat meminimalkan hilangnya detail penting dari gambar asli, sehingga memastikan bahwa informasi yang diperlukan untuk pengenalan pola tetap terjaga dalam proses pengolahan data. Gambar yang akan digunakan diresize menjadi 114x114.



Gambar 2. Citra Resize

3.5. Dataset

Dataset dibuat dan sudah siap untuk digunakan untuk pelatihan dan pengujian model CNN. Data pelatihan digunakan untuk melatih model CNN, dan data pengujian digunakan untuk mengevaluasi kinerja model. Biasanya, dataset dibagi menjadi rasio tertentu, seperti 80% untuk pelatihan dan 20% untuk pengujian[13].


3.6. Convolutional Neural Network (CNN)

CNN dirancang untuk memproses citra-citra yang telah diresize. Arsitektur CNN direncanakan dengan hati-hati untuk menangkap fitur-fitur yang relevan dari citra, termasuk lapisan konvolusi, normalisasi batch, fungsi aktivasi ReLU, dan lapisan max pooling. Desain arsitektur ini merupakan langkah kunci dalam membangun model yang efektif untuk mengklasifikasi antraknosa pada citra cabai rawit. Proses pelatihan model CNN untuk mengklasifikasi kematangan pada citra mentimun melibatkan pengumpulan dataset citra mencakup sampel-sampel dengan dan tanpa ada yang buruk, yang kemudian digunakan untuk melatih model CNN[8].

Langkah-langkah ini mencakup konfigurasi CNN dengan algoritma Adam, RMSprop, SGDM serta penyesuaian arsitektur CNN dengan lapisan imageinput, convolution, relu, maxpool, fully connected, softmax, dan classoutput. Setelah melalui tahap pelatihan, model CNN tersebut dapat digunakan untuk mengenali kematangan pada citra dengan tingkat akurasi yang diharapkan[14]. Setelah pelatihan selesai, model CNN diuji menggunakan dataset pengujian yang terpisah. Citra-citra dalam dataset pengujian tidak digunakan selama pelatihan dan digunakan untuk menguji kemampuan model dalam mengklasifikasi citra-citra baru.

Name	Type	Activations	Learnable Proper...	States
1 imageinput 110-110x110 images with 'centered' nor...	Image Input	110(5) × 110(5) × 3(C) × 1(B)	-	-
2 conv 32 3x3 convolutions with stride (1,1) and...	2-D Convolution	110(5) × 110(5) × 32(C) × 1(B)	Weights: 3 × 3 × 3 = 27 Bias: 1 × 1 × 32	-
3 relu ReLU	ReLU	110(5) × 110(5) × 32(C) × 1(B)	-	-
4 maxpool 5x5 max pooling with stride (1,1) and ga...	2-D Max Pooling	110(5) × 110(5) × 32(C) × 1(B)	-	-
5 fc 2 fully connected layer	Fully Connected	1(5) × 1(5) × 2(C) × 1(B)	Weights: 2 × 415872 Bias: 2 × 1	-
6 softmax softmax	Softmax	1(5) × 1(5) × 2(C) × 1(B)	-	-
7 classoutput classification output	Classification Output	1(5) × 1(5) × 2(C) × 1(B)	-	-

Gambar 3. Desain Arsitektur CNN



Gambar 4. Alur Arsitektur CNN

3.7. Membedakan Buah Matang dan Busuk

Setelah model CNN dilatih menggunakan data pelatihan, tahap berikutnya adalah menguji model untuk membedakan antara buah yang sehat atau terinfeksi antraknosa. Model yang telah dilatih akan diuji dengan data pengujian untuk mengevaluasi akurasi dan kemampuannya dalam mengklasifikasi citra. Hasil akurasi CNN dalam mengklasifikasi antraknosa pada citra buah mentimun dan tomat mencerminkan seberapa baik model tersebut dapat memprediksi dengan tepat kondisi infeksi pada citra, memberikan gambaran tentang efektivitas dan keandalan model dalam tugas klasifikasi yang diberikan. Perhitungan akurasi dengan *confusion matrix* sebagai berikut[15].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Variabel Positif Asli, atau TP, dinilai dari setiap data yang memiliki nilai asli positif dan mengklasifikasikan sistem dengan benar. TP dijumlahkan dengan Variabel Negatif Asli, atau TN, yang dinilai dari setiap data yang memiliki nilai asli negatif dan sistem mengklasifikasikan dengan benar. Untuk menghitung akurasi, TP digabungkan dengan TN. Hasil penjumlahan sebelumnya dibagi dengan TP+FN+FP+TN, di mana FN adalah data negatif yang gagal diklasifikasi oleh sistem dan FP adalah data positif yang gagal diklasifikasi oleh sistem. Total data yang diuji disebut TP+FN+FP+TN[16].

		Prediction Condition	
Actual Condition	Positif	TP	FN
	Negatif	FP	TN

Gambar 5. Confusion Matrix

4. HASIL DAN PEMBAHASAN

Tabel Parameter skenario pengujian menyajikan detail parameter dan nilai-nilai yang digunakan dalam pengembangan dan evaluasi model *Convolutional Neural Network* (CNN) untuk mengklasifikasi kematangan pada citra Mentimun dan Tomat. Parameter utama yang dipertimbangkan meliputi jumlah epoch, optimizer, tingkat pembelajaran awal, fungsi aktivasi, serta konfigurasi lapisan konvolusi, max pooling, dan normalisasi batch.

Tabel 3. Parameter

No	Parameter	Uraian
1	Jumlah Epoch	100
2	Optimizer	Adam, RMSprop, SGDM
3	Tingkat Pembelajaran Awal	0.01
4	Fungsi Aktivasi	ReLU


5	Lapisan Konvolusi	Jumlah : 3, Ukuran Kernel : [3x3]
6	Lapisan Max Pooling	Jumlah : Ukuran Pool : [5x5]
7	Lapisan Normalisasi Batch	Yes
8	Lapisan Fully Connected	Jumlah : 1, jumlah neuron : 2
9	Ukuran Citra Input	114x114x3(RGB)
10	Jumlah Kelas Output	2 (Antraknosa, Normal)
11	Batch Size	Default
12	Metrik Evaluasi	Akurasi
13	Tingkat Pengurutan	Setiap Epoch
14	Frekuensi Validasi	Setiap 5 epoch

Hasil uji model *Convolutional Neural Network* (CNN) untuk Implementasi Tingkat Kematangan Mentimun dan Tomat memperlihatkan perbedaan kinerja berdasarkan jenis optimizer yang diterapkan. Dalam pengujian ini, tiga optimizer yang digunakan adalah Adam, RMSprop, dan *Stochastic Gradient Descent with Momentum* (SGDM). Seluruh pengujian dilakukan dengan membagi dataset menjadi 60% untuk pelatihan dan 40% untuk pengujian. Tingkat pembelajaran awal ditetapkan sebesar 0.01 untuk memulai proses pelatihan dengan langkah pembelajaran yang moderat. Fungsi aktivasi ReLU digunakan untuk memberikan sifat non-linearitas yang dibutuhkan dalam jaringan CNN.


Konfigurasi lapisan seperti konvolusi, max pooling, dan normalisasi batch diatur secara strategis untuk mengoptimalkan proses ekstraksi fitur dan meningkatkan performa model. Dengan menggunakan ukuran citra input 114x114x3 (RGB) dan lapisan fully connected dengan jumlah neuron sebanyak dua untuk mencocokkan output klasifikasi, diharapkan model dapat mengklasifikasikan citra dengan akurasi tinggi antara kelas antraknosa dan normal. Evaluasi model dilakukan dengan menggunakan metrik akurasi, dan validasi dilakukan setiap 5 epoch untuk memantau kinerja model secara periodik dan menghindari overfitting.

Pada pengujian pertama, optimizer Adam menunjukkan hasil terbaik dengan mencapai akurasi sebesar 97% dan nilai loss sebesar 3 %. Adam, yang merupakan singkatan dari Adaptive Moment Estimation, menggabungkan keunggulan metode RMSprop dan Momentum. Dengan menyesuaikan tingkat pembelajaran secara adaptif untuk setiap parameter, Adam menawarkan pelatihan yang lebih stabil dan cepat. Tingkat akurasi yang tinggi dan nilai loss yang rendah menunjukkan bahwa model mampu mengklasifikasikan antraknosa dengan sangat baik dan meminimalkan kesalahan prediksi selama pelatihan. Hasil ini menunjukkan bahwa dengan proporsi data latih yang cukup besar, model mampu mempelajari pola-pola yang kompleks dalam data latih dengan baik, sehingga dapat menghasilkan hasil yang lebih akurat. Grafik akurasi pengujian hasil akurasi dan loss dengan optimizer Adam buah


mentimun dan tomat dapat dilihat pada gambar dibawah ini.




Gambar 6. Hasil Akurasi Mentimun



Gambar 7. Hasil Loss Mentimun



Gambar 8. Hasil Akurasi Tomat



Gambar 9. Hasil Loss Tomat

Optimizer kedua yang diuji dalam penelitian ini adalah RMSprop, yang menghasilkan akurasi 92% dan nilai loss sebesar 8%. Metode RMSprop menyesuaikan tingkat pembelajaran dengan rata-rata eksponensial gradien sebelumnya. Walaupun akurasi yang diperoleh sedikit lebih rendah dibandingkan dengan Adam, RMSprop tetap menunjukkan performa yang baik dengan akurasi di atas 90%. Namun, nilai loss yang lebih tinggi dibandingkan Adam menunjukkan bahwa ada potensi perbaikan dalam hal stabilitas dan penyesuaian parameter model ini.

Pada uji coba terakhir dengan optimizer SGDM, model mencapai akurasi sebesar 94.00% dan nilai loss 6.00%. SGDM melakukan pembaruan parameter dengan memperhitungkan momentum, yang dapat mengurangi fluktuasi gradien dan mempercepat proses konvergensi. Meskipun akurasi yang diperoleh lebih rendah dibandingkan Adam dan RMSprop, SGDM masih menghasilkan tingkat akurasi yang cukup memadai. Nilai loss yang lebih tinggi menunjukkan bahwa model dengan SGDM mungkin memerlukan lebih banyak epoch atau penyesuaian parameter untuk meningkatkan hasilnya.

Temuan dari pengujian ini menggaris bawahi betapa pentingnya pemilihan optimizer dalam memengaruhi kinerja model CNN untuk

Implementasi Tingkat Kematangan Mentimun dan Tomat. Optimizer Adam menunjukkan performa terbaik dengan akurasi tertinggi dan nilai loss terendah, menandakan efisiensi dan keefektifannya dalam penyesuaian parameter selama pelatihan. RMSprop, meskipun sedikit kurang unggul dibandingkan Adam, tetap memberikan hasil yang kompetitif. SGDM, walaupun akurasinya lebih rendah, tetap menjadi opsi yang baik, terutama untuk pelatihan jangka panjang dengan penyesuaian parameter yang lebih mendalam.

Secara keseluruhan, hasil pengujian ini menegaskan pentingnya pemilihan optimizer yang tepat dalam pelatihan model CNN untuk tugas klasifikasi spesifik. Perbedaan akurasi dan nilai loss yang dicapai oleh masing-masing optimizer memberikan insight berharga tentang bagaimana setiap metode memengaruhi proses pembelajaran model. Akurasi tertinggi yang dicapai adalah 93.25% dengan menggunakan optimizer Adam.

Hasil confusion matrix dari klasifikasi menggunakan *Convolutional Neural Network* (CNN) menunjukkan bahwa optimizer Adam memberikan kinerja terbaik dengan akurasi 99 data dan nilai loss 1 untuk mentimun yang matang, serta akurasi 95 data dan nilai loss 5 untuk mentimun yang buruk. Optimizer RMSprop juga memberikan hasil yang cukup baik dengan akurasi 176 data dan nilai loss 24 untuk mentimun matang, serta akurasi 192 data dan nilai loss 8 untuk mentimun yang buruk. Optimizer SGDM menunjukkan kinerja sedikit di bawah, dengan akurasi 99 data dan nilai loss 1 untuk mentimun yang matang, serta akurasi 95 data dan nilai loss 5 untuk mentimun buruk. Begitu juga pada optimizer Adam memberikan kinerja terbaik dengan akurasi 187 data dan nilai loss 13 untuk tomat yang matang, serta akurasi 182 data dan nilai loss 18 untuk tomat yang buruk. Optimizer RMSprop juga memberikan hasil yang cukup baik dengan akurasi 176 data dan nilai loss 24 untuk tomat matang, serta akurasi 192 data dan nilai loss 8 untuk tomat yang buruk. Optimizer SGDM menunjukkan kinerja sedikit di bawah, dengan akurasi 99 data dan nilai loss 1 untuk tomat yang matang, serta akurasi 95 data dan nilai loss 5 untuk tomat buruk. menunjukkan bahwa pemilihan optimizer sangat mempengaruhi kinerja model CNN dalam implementasi, dengan Adam memberikan hasil paling optimal, diikuti oleh RMSprop dan SGDM.

True Class	Predicted Class	
	Buruk	Matang
Buruk	95	5
Matang	1	99

Gambar 10. Confusion Matrix Mentimun

True Class	Predicted Class	
	Tomat Busuk	Tomat Matang
Tomat Busuk	182	18
Tomat Matang	13	187

Gambar 11. Confusion Matrix Tomat

5. KESIMPULAN DAN SARAN

Dalam penelitian ini, penerapan metode *Convolutional Neural Network* (CNN) untuk Implementasi Tingkat Kematangan Mentimun dan Tomat menunjukkan hasil yang signifikan. Penggunaan tiga optimizer Adam, RMSprop, dan SGDM mengungkapkan bahwa Adam memberikan performa terbaik dengan akurasi mencapai 97% dan nilai loss terendah 3%. Adam berhasil mencapai hasil optimal karena kemampuannya menyesuaikan tingkat pembelajaran secara adaptif, yang meningkatkan stabilitas dan efisiensi pelatihan. Sementara itu, RMSprop dan SGDM menunjukkan akurasi yang kompetitif, masing-masing dengan nilai 92% dan 94%, tetapi dengan nilai loss yang lebih tinggi dibandingkan Adam. Temuan ini menegaskan pentingnya pemilihan optimizer yang tepat untuk memaksimalkan akurasi dan efisiensi dalam deteksi penyakit berbasis citra.

Disarankan untuk menggunakan teknik augmentasi data, memperluas dataset, mencoba arsitektur CNN lainnya seperti ResNet atau VGG, melakukan penyesuaian hyperparameter, dan melakukan evaluasi lebih lanjut menggunakan metrik seperti Precision, Recall, dan F1-score. Implementasi dalam sistem nyata dan kolaborasi dengan ahli pertanian juga penting untuk validasi hasil model dan penerapan praktis di lapangan.

DAFTAR PUSTAKA

- [1] A. Pujiyanta and S. Rizqiawan, *Identifikasi Kematangan Mentimun Berdasarkan Tekstur Kulit Buah dengan Fuzzy C-Mean*. 2016.
- [2] J. Sains dan Teknologi, J. Jumadi, and D. Sartika, "PENGOLAHAN CITRA DIGITAL UNTUK IDENTIFIKASI OBJEK MENGGUNAKAN METODE HIERARCHICAL AGGLOMERATIVE CLUSTERING".
- [3] A. Hibatullah and I. Maliki, "PENERAPAN METODE CONVOLUTIONAL NEURAL NETWORK PADA PENGENALAN POLA CITRA SANDI RUMPUT."
- [4] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural

- Network (CNN),” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 2, p. 466, Apr. 2023, doi: 10.26760/elkomika.v11i2.466.
- [5] Y. Bili *et al.*, “Perancangan Alat Pendeteksi Kematangan Buah Nanas Dengan Menggunakan Mikrokontroler Dengan Metode Convolutional Neural Network (CNN),” 2022. [Online]. Available: <http://ojs.fikom-methodist.net/index.php/METHOTIKA>
- [6] A. Ridhoi, “Penerapan Pengolahan Citra Untuk Perbaikan Gambar 2 Dimensi Dengan Menggunakan Matlab,” *Joutica*, vol. 8, no. 1, pp. 64–69, 2023, doi: 10.30736/informatika.v8i1.1063.
- [7] M. Fahmi and A. Yudhana, “Pemilahan Sampah Menggunakan Model Klasifikasi Support Vector Machine Gabungan dengan Convolutional Neural Network,” *Jurnal Riset Komputer*, vol. 10, no. 1, pp. 2407–389, 2023, doi: 10.30865/jurikom.v10i1.5468.
- [8] I. Arias-Serrano *et al.*, “Artificial intelligence based glaucoma and diabetic retinopathy detection using MATLAB — retrained AlexNet convolutional neural network,” *F1000Res*, vol. 12, p. 14, Jan. 2023, doi: 10.12688/f1000research.122288.1.
- [9] Y. Reswan, R. Toyib, H. Witriyono, and A. Anggraini, “Klasifikasi Tingkat Kematangan Buah Nanas Berdasarkan Fitur Warna Menggunakan Metode K-Nearest Neighbor (KNN),” *Jurnal Media Infotama*, vol. 20, no. 1, 2024.
- [10] S. A. Maulana *et al.*, “Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur,” *Jurnal Penelitian Rumpun Ilmu Teknik (JUPRIT)*, vol. 2, no. 4, pp. 122–130, 2023, doi: 10.55606/juprit.v2i4.3084.
- [11] I. E. Handayani and D. Avianto, “Klasifikasi Penyakit Antraknosa Pada Cabai Merah Teropong ‘Inko Hot’ Dengan Metode Convolutional Neural Network”, [Online]. Available: <https://doi.org/10.31598>
- [12] A. Ciofini, F. Negrini, R. Baroncelli, and E. Baraldi, “Management of Post-Harvest Anthracnose: Current Approaches and Future Perspectives,” Jul. 01, 2022, *MDPI*. doi: 10.3390/plants11141856.
- [13] KLASIFIKASI LEVEL KEMATANGAN BUAH TOMAT BERDASARKAN FITUR WARNA MENGGUNAKAN MULTI-SVM
- [14] SISTEM PERANCANGAN ALAT PENDETEKSI TINGKAT KEMATANGAN BUAH TOMAT MENGGUNAKAN SENSOR WARNA BERBASIS ARDUINO