

MENGEMBANGKAN MODEL CNN UNTUK KLASIFIKASI TINGKAT KEMATANGAN BUAH NANAS BERDASARKAN CITRA DIGITAL

¹Fanisha Juliananda Putri, ²Muh.Rasyid Ridha

^{1,2}Program Studi Sistem Informasi, Fakultas Teknik dan Ilmu Komputer
Universitas Islam Indragiri

Jl. Provinsi No. 01 Tembilahan Hulu, Indragiri Hilir, Riau - Indonesia

Email: fanishajuliananda77@gmail.com, rasyid4sky@gmail.com

ABSTRAK

Penentuan tingkat kematangan buah nanas umumnya masih dilakukan secara manual melalui pengamatan visual, sehingga hasilnya sering bersifat subjektif dan tidak konsisten. Kondisi ini dapat mengakibatkan kesalahan dalam proses panen, sortasi, maupun distribusi yang berdampak pada penurunan kualitas dan kerugian ekonomi. Untuk mengatasi permasalahan tersebut, penelitian ini merancang dan mengembangkan model Convolutional Neural Network (CNN) yang mampu mengklasifikasikan tingkat kematangan buah nanas secara otomatis berdasarkan citra digital. CNN digunakan karena kemampuannya mengekstraksi pola warna dan tekstur yang menjadi indikator utama perubahan kematangan. Pengembangan model dilakukan melalui tahapan pengumpulan dataset citra nanas dari berbagai kondisi, *preprocessing* seperti normalisasi dan *augmentation*, serta perancangan arsitektur CNN dengan lapisan konvolusi, *pooling*, dan *fully connected*. Hasil pengujian menunjukkan bahwa model CNN mampu mengenali tingkat kematangan dengan akurasi tinggi dan performa stabil pada seluruh kategori. Temuan ini menunjukkan bahwa CNN dapat menjadi solusi objektif dan efisien untuk sistem sortasi buah nanas, serta berpotensi diterapkan dalam proses penilaian kualitas otomatis pada industri hortikultura modern.

Keywords: CNN, klasifikasi citra, kematangan nanas, pengolahan citra digital, deep learning.

1 PENDAHULUAN

Penentuan tingkat kematangan buah umumnya masih dilakukan secara manual melalui pengamatan visual, yang bersifat subjektif dan sangat bergantung pada pengalaman manusia. Ketergantungan pada penilaian manual dapat menyebabkan ketidakkonsistenan dan kesalahan dalam klasifikasi kualitas buah, terlebih ketika variasi warna dan tekstur buah muncul dalam kondisi pencahayaan yang berbeda-beda. Hal ini mendorong kebutuhan akan metode otomatis yang lebih objektif dan dapat diandalkan dalam proses sortasi buah berbasis citra digital [1].

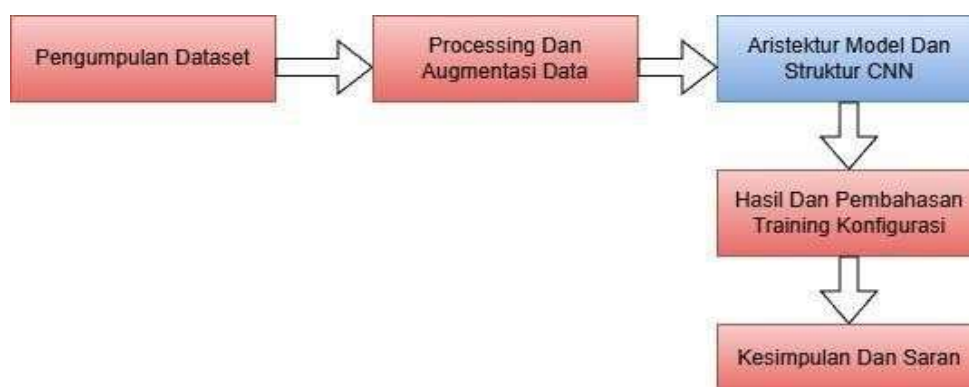
Convolutional Neural Network (CNN) merupakan metode deep learning yang telah banyak digunakan dalam klasifikasi citra karena kemampuannya dalam mengekstraksi fitur visual secara otomatis melalui lapisan konvolusi dan *pooling*. CNN telah diterapkan dalam berbagai studi klasifikasi buah, seperti pada klasifikasi citra buah pir yang berhasil menunjukkan performa akurasi tinggi dalam membedakan jenis buah berdasarkan gambar [1]. Metode ini lebih sering digunakan dibandingkan pendekatan tradisional yang masih memerlukan ekstraksi fitur manual. Selain itu, implementasi CNN juga telah diterapkan pada pengenalan dan klasifikasi buah berbasis citra digital dengan hasil yang menunjukkan efektivitas tinggi dalam mengidentifikasi kelas objek secara otomatis tanpa tergantung pada proses manual [2]. Kemampuan CNN dalam mengenali pola visual yang kompleks membuatnya menjadi pendekatan yang relevan untuk klasifikasi tingkat kematangan dan kualitas buah nanas secara otomatis. Oleh karena itu, pengembangan model CNN untuk klasifikasi citra buah nanas sangat penting dalam mendukung sistem sortasi buah yang efisien dan objektif. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model *Convolutional Neural Network* (CNN) yang mampu mengklasifikasikan tingkat kematangan buah nanas secara otomatis berdasarkan citra digital dengan tingkat akurasi yang baik.

2 TINJAUAN PUSTAKA

Penerapan model klasifikasi berbasis *machine learning* dan *deep learning* pada bidang pertanian terus berkembang, khususnya dalam analisis citra buah dan tanaman. Pendekatan *Convolutional Neural Network (CNN)* terbukti efektif dalam mendeteksi penyakit buah jeruk melalui penggabungan CNN dengan metode *Gradient Boosting* sehingga mampu meningkatkan akurasi prediksi secara signifikan [3]. Selain itu, CNN juga digunakan untuk klasifikasi kematangan dan ukuran buah nanas berbasis citra digital dengan performa yang stabil pada data pelatihan dan pengujian [4]. Model CNN lainnya diterapkan untuk klasifikasi kematangan buah kopi dengan memanfaatkan karakteristik warna dan tekstur citra sebagai fitur utama [5]. Pendekatan klasifikasi berbasis CNN juga dikembangkan untuk klasifikasi buah secara umum dan menunjukkan keunggulan dibandingkan metode konvensional berbasis ekstraksi fitur manual [6]. Hasil penelitian lain menunjukkan bahwa CNN efektif digunakan untuk berbagai jenis tugas klasifikasi citra pertanian karena kemampuannya dalam mengekstraksi fitur visual secara otomatis [7].

Selain CNN, metode klasifikasi lain seperti *Support Vector Machine (SVM)* masih banyak digunakan dan menunjukkan performa yang kompetitif dalam klasifikasi citra pertanian. Penggunaan SVM dengan optimasi parameter mampu meningkatkan akurasi klasifikasi tingkat kematangan buah kopi secara signifikan [8]. Kombinasi teknik ekstraksi fitur tekstur dengan seleksi fitur dan classifier SVM juga terbukti meningkatkan performa klasifikasi pada objek tanaman rimpang [9]. Penelitian lain mengembangkan model klasifikasi berbasis CNN untuk mendeteksi penyakit daun dan buah dengan tingkat akurasi tinggi pada berbagai dataset pertanian [10]. Pendekatan *deep learning* modern seperti CNN juga digunakan dalam klasifikasi penyakit tanaman dan buah pada skala besar dengan memanfaatkan dataset citra resolusi tinggi [11]. Secara keseluruhan, hasil-hasil penelitian tersebut menunjukkan bahwa baik CNN maupun metode klasifikasi tradisional seperti SVM memiliki peran penting dalam pengembangan sistem klasifikasi citra pertanian yang akurat dan andal [12].

3 METODE PENELITIAN




Gambar 1. Kerangka Penelitian

3.1 Pengumpulan Dataset

Pengumpulan dataset merupakan tahap awal penelitian yang bertujuan memperoleh citra buah nanas yang representatif sebagai data masukan bagi model klasifikasi. Dataset dikumpulkan dengan memperhatikan variasi visual dan pembagian kelas tingkat kematangan agar data yang digunakan mampu merepresentasikan kondisi nyata serta mendukung proses pelatihan dan pengujian model secara optimal. Penentuan tingkat kematangan buah nanas mengacu pada indikator agronomi yang umum digunakan, yaitu perubahan warna kulit buah dari hijau menuju kuning keemasan sebagai penanda kematangan. Buah mentah didominasi warna hijau, buah setengah matang menunjukkan kombinasi warna hijau dan kuning, sedangkan buah matang memiliki dominasi warna kuning keemasan pada permukaan kulit (Postharvest Research and Extension Center, University of California Davis). Oleh karena itu, pengambilan citra difokuskan

untuk menangkap variasi warna kulit buah nanas sebagai dasar pelabelan kelas kematangan, yaitu mentah, setengah matang, dan matang, sesuai dengan standar *maturity indices* pascapanen buah. Data diambil langsung dilapangan di beberapa tempat seperti perkebunan nanas dan juga pasar yang ada di kabupaten Indragiri Hilir. data diambil menggunakan kamera handphone A60 dengan rasio penangkapan citra buah nanas 1:1 dengan berbagai sudut dan pencahayaan alami langsung dilapangan.



Gambar 2. (a) Unripe, (b) Pre-ripe, (c) Half-ripe, (d) Fullyripe

Dataset yang digunakan dalam penelitian ini berjumlah 4.000 citra buah nanas. Data tersebut dibagi menjadi data pelatihan (training), data validasi (validation), dan data uji (testing) untuk memastikan proses pelatihan dan evaluasi model berjalan secara objektif. Pembagian data dilakukan dengan perbandingan 70% untuk data pelatihan dan 15% untuk data validasi, dan data uji 15% . Rincian pembagian dataset disajikan pada tabel berikut.

Tabel 1 Jumlah Dataset perkelas

Kelas	Jumlah Citra
Mentah	1.000
Mengkal	1.000
Setengah Matang	1.000
Matang	1.000
TOTAL	4.000

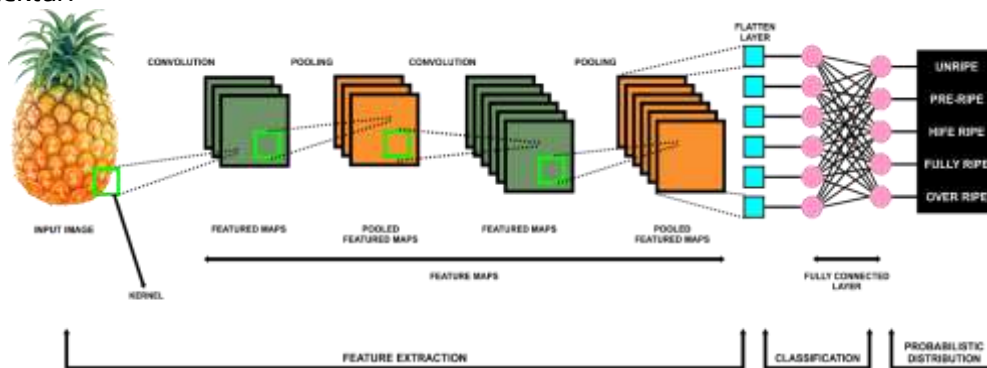
Tabel 2. Pembagian Data set

Jenis Data	Presentase	Jumlah Citra
Data Training	70%	2.800
Data Validasi	15%	600
Data Uji	15%	600
TOTAL	100%	4.000

3.2 Proecssing dan Augmentasi Data

1. Processing Data. Pada tahap preprocessing data, seluruh citra buah nanas diubah ukurannya (resize) menjadi 128×128 piksel menggunakan fungsi `image_dataset_from_directory` agar seluruh data memiliki dimensi yang seragam. Selanjutnya, dilakukan normalisasi nilai piksel dengan mengubah rentang intensitas dari 0–255 menjadi 0–1 menggunakan layer `Rescaling(1./255)` pada model CNN.. Tahap processing ini bertujuan untuk mengurangi variasi yang tidak relevan sehingga model dapat mempelajari fitur visual buah nanas secara optimal.
2. Augmentasi Data. Tahap augmentasi data dilakukan untuk menambah variasi dataset dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang diterapkan meliputi rotasi citra sebesar 90°, resize, zoom, flip (pembalikan citra), serta perubahan nilai warna dan kecerahan. Augmentasi ini bertujuan untuk mensimulasikan variasi kondisi pengambilan gambar di lapangan tanpa mengubah karakteristik utama buah nanas, sehingga dapat mengurangi risiko *overfitting* pada model klasifikasi.
3. Aritektur Model CNN. Pada fase ini, citra buah nanas yang telah melalui tahap processing dan augmentasi digunakan sebagai masukan (*input*) ke dalam model *Convolutional Neural Network*

(CNN). Arsitektur CNN diawali dengan convolution layer yang berfungsi mengekstraksi fitur visual penting seperti pola warna, tekstur, dan tepi pada permukaan buah nanas. Setiap convolution layer diikuti oleh activation function (ReLU) untuk meningkatkan kemampuan nonlinier model, serta pooling layer untuk mereduksi dimensi fitur dan mempertahankan informasi utama. Fitur hasil ekstraksi kemudian diratakan (*flatten*) dan diteruskan ke fully connected layer yang berperan dalam proses klasifikasi. Pada tahap akhir, output layer dengan fungsi aktivasi *softmax* digunakan untuk menghasilkan probabilitas kelas tingkat kematangan buah nanas, yaitu *unripe*, *pre-ripe*, *half-ripe*, *fully ripe*, sebagaimana ditunjukkan pada diagram arsitektur.



Gambar 3. Arsitektur Model

Pemilihan arsitektur CNN dengan tiga lapisan konvolusi dilakukan untuk mempelajari fitur citra secara bertahap dari tingkat sederhana hingga kompleks. Lapisan konvolusi pertama mengekstraksi fitur dasar seperti tepi dan perbedaan warna dominan pada permukaan nanas. Lapisan kedua memperkuat pembelajaran pola tekstur kulit dan kombinasi warna yang mulai berubah pada fase pre-ripe dan half-ripe. Lapisan ketiga digunakan untuk menangkap fitur tingkat tinggi yang lebih spesifik sehingga mampu membedakan kelas yang memiliki karakteristik visual mirip. Arsitektur tiga lapisan ini dipilih karena cukup representatif untuk dataset berukuran sedang serta dapat menghindari model menjadi terlalu kompleks yang berpotensi memicu overfitting. otomatis berdasarkan karakteristik visual citra. Pada penelitian ini, proses pelatihan model CNN dilakukan dengan menggunakan beberapa hyperparameter yang ditentukan sebelum pelatihan dimulai. Hyperparameter tersebut berperan penting dalam mengontrol proses pembelajaran model, seperti ukuran citra masukan, jumlah epoch, batch size, optimizer, dan learning rate. Penentuan nilai hyperparameter disesuaikan dengan karakteristik dataset serta arsitektur model CNN yang digunakan. Rincian hyperparameter yang diterapkan pada penelitian ini disajikan pada Tabel 3.

Tabel 3. Hyperparameter Model CNN

No	Hyperparameter	Nilai
1	Image size	128x128 piksel
2	Channel warna	RGB(3 warna)
3	Normalisasi piksel	1/255
4.	Batch size	32
5.	Epoch	30
6.	Optimizer	Adam
7.	Leraming rate	0.001
8.	Loss fuction	Categorical crossentropy
9.	Metrics	Accuracy
10.	Valiation split	0.2(20%)
11.	Total Parameter	7.392.836
12	Trainble parameter	7.392.836

Model klasifikasi pada penelitian ini menggunakan arsitektur Convolutional Neural Network (CNN) dengan pendekatan *Sequential*. Susunan lapisan, ukuran keluaran, dan jumlah parameter model CNN yang digunakan disajikan pada Tabel 4 dibawah ini.

Tabel 4. Struktur Arsitektur CNN

Layer	Jenis Layer	Jumlah Parameter
Rescaling	Normalisasi	0
Conv2D	Convolution	896
MaxPooling2D	Pooling	0
Conv2D_1	Convolution	18,496
MaxPooling2D_1	Pooling	0
Conv2D_2	Convolution	73,856
MaxPooling2D_2	Pooling	0
Flatten	Flatten	0
Dense	Fully Connected	3,21,392
Dropout	Regularisasi	0
Dense_1	Output Layer	516

Berdasarkan Tabel, Total parameter yang ada 3.305.58, Trainable parameter 3.305.156, dan Non trainable parameter 0 arsitektur CNN yang digunakan terdiri dari beberapa lapisan konvolusi dan pooling untuk mengekstraksi fitur visual citra buah nanas, yang kemudian diikuti oleh lapisan fully connected sebagai tahap klasifikasi. Susunan lapisan tersebut memungkinkan model mempelajari perbedaan tingkat kematangan buah nanas secara bertahap berdasarkan karakteristik visual citra.

Pada penelitian ini, proses pelatihan model Convolutional Neural Network (CNN) menggunakan optimizer Adaptive Moment Estimation (Adam). Optimizer Adam merupakan metode optimasi berbasis gradien yang menggabungkan konsep Momentum dan Root Mean Square Propagation (RMSProp) untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembaruan bobot selama pelatihan model. Adam menghitung estimasi momen pertama dan momen kedua dari gradien secara adaptif pada setiap parameter, sehingga mampu menyesuaikan laju pembelajaran secara otomatis.

Penggunaan optimizer Adam dipilih karena kemampuannya dalam menangani permasalahan optimasi pada model dengan jumlah parameter yang besar serta data berdimensi tinggi, seperti pada citra digital. Pada penelitian ini, optimizer Adam diterapkan dengan learning rate sebesar 0,001, yang bertujuan untuk menjaga keseimbangan antara kecepatan konvergensi dan kestabilan proses pelatihan. Dengan penggunaan optimizer Adam, model CNN diharapkan dapat mencapai performa klasifikasi yang optimal dalam mengenali tingkat kematangan buah nanas berdasarkan karakteristik visual citra.

4 HASIL DAN PEMBAHASAN


4.1 Hasil Pelatihan Model CNN

Proses pelatihan model Convolutional Neural Network (CNN) dilakukan selama 30 epoch menggunakan data training dan validasi. Tujuan pelatihan ini adalah untuk mengevaluasi kemampuan model dalam mempelajari pola visual citra buah nanas serta mengamati stabilitas proses pembelajaran selama iterasi berlangsung. Evaluasi hasil pelatihan dilakukan dengan menganalisis perubahan nilai akurasi dan loss pada data training dan validasi, yang ditampilkan dalam bentuk grafik untuk memudahkan interpretasi performa model.

Grafik akurasi training dan validasi disajikan untuk menunjukkan perkembangan kemampuan model dalam melakukan klasifikasi seiring bertambahnya jumlah epoch. Sementara itu, grafik loss training dan validasi digunakan untuk mengamati tingkat kesalahan prediksi model selama proses pelatihan serta mendeteksi adanya indikasi overfitting atau underfitting.

Berdasarkan grafik akurasi dan loss pada Gambar 4. Grafik Akurasi Training dan Validasi dan Grafik Loss Training dan Validasi, terlihat bahwa akurasi training mengalami peningkatan yang signifikan sejak epoch awal dan mencapai nilai mendekati 1,00 pada akhir pelatihan, yang

menunjukkan bahwa model CNN mampu mempelajari pola visual citra buah nanas dengan sangat baik pada data pelatihan. Sementara itu, akurasi validasi menunjukkan peningkatan yang lebih fluktuatif dan mencapai nilai sekitar 0,80 pada epoch ke-30, yang mengindikasikan adanya perbedaan performa antara data training dan data validasi. Grafik loss training memperlihatkan penurunan yang konsisten hingga mendekati nol, sedangkan loss validasi cenderung berfluktuasi dan meningkat pada beberapa epoch tertentu. Kondisi tersebut menunjukkan adanya kecenderungan overfitting ringan.

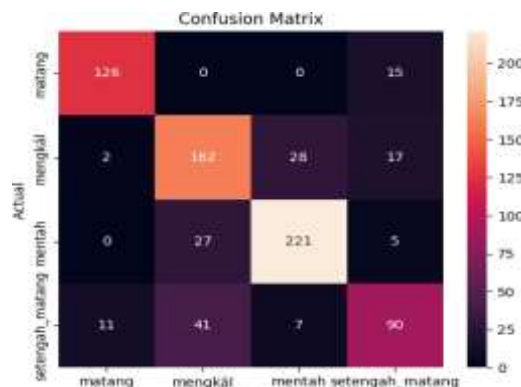


Gambar 4. Grafik Akurasi Training&Validasi,Grafik Loss Training&Validasi

Pola grafik pada Gambar 4.1 menunjukkan indikasi overfitting, ditandai dengan akurasi training yang terus meningkat hingga mendekati 1,00 sedangkan akurasi validasi cenderung fluktuatif dan berada pada nilai yang lebih rendah. Kondisi ini menandakan bahwa model sangat baik dalam mengenali pola pada data latih, tetapi kemampuan generalisasi pada data yang belum pernah dilihat masih terbatas. Salah satu penyebabnya adalah perbedaan karakteristik citra antara data training dan validasi, seperti variasi pencahayaan, sudut pengambilan gambar, dan latar belakang, sehingga model lebih mudah “menghafal” pola pada data latih dibanding memahami pola umum tingkat kematangan. Selain itu, kenaikan loss validasi pada beberapa epoch terjadi karena kelas kematangan seperti pre-ripe (mengkal) dan half-ripe (setengah matang) memiliki kemiripan warna yang sangat dekat, sehingga kesalahan prediksi lebih sering muncul pada data validasi.

4.2 Hasil Pengujian Model Menggunakan Confusion Matrix

Pengujian model CNN dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan dengan tujuan untuk mengevaluasi kemampuan generalisasi model dalam mengklasifikasikan tingkat kematangan buah nanas. Evaluasi performa model pada data uji dilakukan menggunakan confusion matrix, yang memberikan gambaran rinci mengenai jumlah prediksi yang benar dan salah pada setiap kelas kematangan. Melalui confusion matrix, dapat dianalisis pola kesalahan klasifikasi serta tingkat ketepatan model dalam mengenali masing-masing kelas.



Gambar 5. Confusion Matrix

Berdasarkan confusion matrix pada Gambar 4.2, sebagian besar data uji berhasil diklasifikasikan dengan benar oleh model CNN, yang ditunjukkan oleh nilai tinggi pada diagonal utama matriks. Kelas *matang* menunjukkan tingkat klasifikasi yang paling baik dibandingkan kelas

lainnya, sementara kesalahan klasifikasi paling sering terjadi pada kelas *mengkal* dan *setengah matang*. Hal ini disebabkan oleh kemiripan karakteristik visual, terutama warna dan tekstur kulit buah, pada kedua kelas tersebut. Secara keseluruhan, hasil pengujian menunjukkan bahwa model CNN mampu mencapai akurasi sebesar **80%**, yang menandakan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital.

Untuk memberikan gambaran yang lebih rinci mengenai kinerja model CNN pada setiap kelas tingkat kematangan buah nanas, dilakukan evaluasi lanjutan menggunakan metrik precision, recall, dan f1-score. Metrik-metrik tersebut digunakan untuk menilai tingkat ketepatan prediksi, kemampuan model dalam mengenali data aktual, serta keseimbangan antara precision dan recall pada masing-masing kelas. Selain itu, jumlah data pada setiap kelas (support) juga disertakan untuk menunjukkan distribusi data uji yang digunakan dalam evaluasi. Hasil evaluasi kinerja model secara kuantitatif disajikan pada Tabel 5.

Tabel 5. Hasil Evaluasi Kerja Model CNN

Kelas	Precision	Recall	F1—Score	Support
Matang	0.91	0.89	0.90	141
Mengkal	0.70	0.78	0.74	209
Mentah	0.86	0.87	0.87	253
Setengan Matang	0.71	0.60	0.65	149

Berdasarkan hasil evaluasi yang disajikan pada Tabel 4.1, model CNN menghasilkan akurasi keseluruhan sebesar 80% pada data uji sebanyak 752 citra. Kelas *matang* menunjukkan performa terbaik dengan nilai precision sebesar 0,91, recall 0,89, dan f1-score 0,90, yang menandakan bahwa model mampu mengklasifikasikan kelas tersebut dengan tingkat ketepatan yang tinggi. Kelas *mentah* juga menunjukkan performa yang baik dengan nilai f1-score sebesar 0,87, sedangkan kelas *mengkal* memiliki nilai f1-score sebesar 0,74. Sementara itu, kelas *setengah matang* menunjukkan nilai f1-score terendah, yaitu 0,65, yang mengindikasikan bahwa kelas tersebut paling sulit diklasifikasikan oleh model

4.3 Perbandingan Model CNN dengan Baseline SVM

Sebagai pembandingan performa, penelitian ini juga menguji metode baseline menggunakan Support Vector Machine (SVM). SVM dipilih karena merupakan salah satu metode machine learning klasik yang banyak digunakan dalam klasifikasi citra, terutama ketika fitur citra diperoleh melalui representasi numerik. Penggunaan baseline bertujuan untuk memastikan bahwa performa model CNN yang dikembangkan memiliki keunggulan yang terukur dibandingkan metode konvensional.

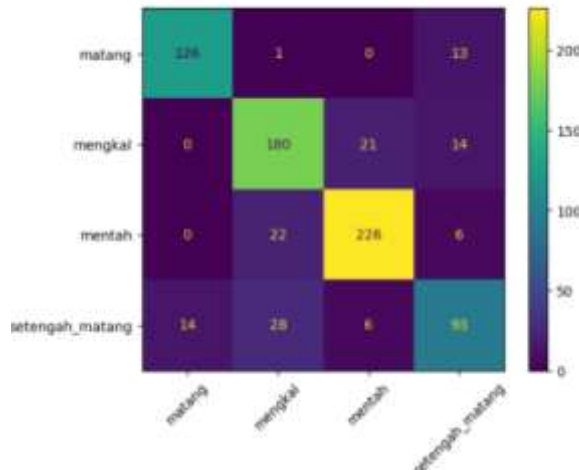
Untuk memberikan pembandingan (baseline) terhadap model CNN, penelitian ini juga melakukan pengujian menggunakan metode Support Vector Machine (SVM). Evaluasi dilakukan menggunakan metrik precision, recall, f1-score, serta confusion matrix untuk melihat performa klasifikasi pada setiap kelas kematangan nanas. Berdasarkan hasil pengujian, model SVM memperoleh akurasi sebesar 83,33%, dengan performa terbaik pada kelas matang dan mentah, sedangkan kesalahan prediksi masih sering terjadi pada kelas mengkal dan setengah matang karena karakteristik visual yang saling berdekatan. Perbandingan hasil evaluasi antara CNN dan SVM disajikan pada Tabel 6.

Tabel 6. Evlusi kinerja model SVM

Kelas	Precision	Recall	F1-Score	Support
Matang	0.90	0.90	0.90	140
Mengkal	0.78	0.84	0.81	215
Mentah	0.89	0.89	0.89	254
Setengah Matang	0.74	0.66	0.70	141

Untuk membandingkan performa model CNN yang diusulkan, penelitian ini juga melakukan pengujian menggunakan metode baseline Support Vector Machine (SVM). Evaluasi dilakukan

menggunakan confusion matrix untuk melihat jumlah prediksi benar dan kesalahan klasifikasi pada setiap kelas tingkat kematangan buah nanas.



Gambar 6. Confusion Matrix SVM

Berdasarkan hasil evaluasi pada Tabel 4. Dan Gambar 6, model Support Vector Machine (SVM) memperoleh akurasi keseluruhan sebesar 83,33% pada data uji. Kelas matang menunjukkan performa terbaik dengan nilai precision, recall, dan f1-score yang tinggi, sedangkan kelas setengah matang memiliki nilai f1-score terendah dibandingkan kelas lainnya. Hal ini menunjukkan bahwa kelas setengah matang merupakan kelas yang paling sulit dibedakan oleh model karena memiliki karakteristik visual yang mendekati kelas mengkal.

Selaras dengan hasil tersebut, confusion matrix pada Gambar 4.X memperlihatkan bahwa sebagian besar data uji telah diklasifikasikan dengan benar (ditunjukkan pada diagonal utama). Namun, masih terdapat kesalahan prediksi yang cukup dominan antara kelas mengkal dan setengah matang, yang disebabkan oleh kemiripan perubahan warna kulit dan tekstur buah pada fase transisi kematangan. Secara keseluruhan, hasil pengujian ini menunjukkan bahwa SVM dapat digunakan sebagai baseline pembandingan yang kompetitif terhadap model CNN dalam penelitian ini.

Tabel 7. Perbandingan Akurasi Model CNN dan SVM

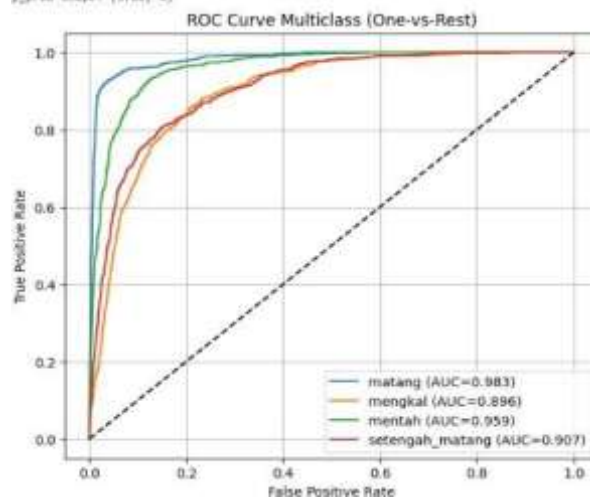
Model	Akurasi
CNN	80%
SVM(Baseline)	83,33%

metode SVM memperoleh akurasi sedikit lebih tinggi dibandingkan CNN. Namun demikian, model CNN tetap menunjukkan performa yang kompetitif karena mampu melakukan klasifikasi dengan pendekatan end-to-end, yaitu mengekstraksi fitur visual secara otomatis dari citra tanpa memerlukan proses ekstraksi fitur manual. Keunggulan ini menjadikan CNN lebih fleksibel untuk dikembangkan pada sistem klasifikasi kematangan buah berbasis citra, terutama ketika dataset diperluas dan variasi kondisi pengambilan gambar semakin beragam.

Akurasi CNN yang lebih rendah pada penelitian ini dapat dipengaruhi oleh beberapa faktor, seperti kemiripan karakteristik visual antar kelas (khususnya kelas mengkal dan setengah matang) serta adanya indikasi overfitting ringan pada proses pelatihan. Kondisi tersebut menyebabkan model lebih mudah mempelajari pola pada data latih dibandingkan melakukan generalisasi pada data uji. Meskipun demikian, hasil evaluasi menggunakan confusion matrix dan metrik f1-score menunjukkan bahwa CNN sudah mampu mengenali kelas matang dan mentah dengan baik, sehingga model tetap layak digunakan sebagai dasar sistem klasifikasi otomatis dan dapat ditingkatkan pada penelitian selanjutnya melalui optimasi hyperparameter, early stopping, serta penerapan transfer learning dengan arsitektur CNN yang lebih modern.

4.4 Analisis Kinerja Model Menggunakan Kurva ROC–AUC

Selain menggunakan confusion matrix, evaluasi kinerja model CNN juga dilakukan menggunakan kurva Receiver Operating Characteristic (ROC) dan nilai Area Under Curve (AUC). Evaluasi ROC–AUC digunakan untuk mengukur kemampuan model dalam membedakan setiap kelas tingkat kematangan buah nanas secara lebih komprehensif. Pada penelitian ini, analisis ROC–AUC diterapkan pada skenario klasifikasi multikelas dengan pendekatan *one-vs-rest*, di mana setiap kelas dibandingkan terhadap kelas lainnya.



Gambar 7. Kurva ROC-AUC

Berdasarkan kurva ROC–AUC pada Gambar 7, terlihat bahwa model CNN memiliki kemampuan diskriminasi yang baik dalam membedakan setiap kelas tingkat kematangan buah nanas. Kelas *matang* menunjukkan nilai AUC tertinggi sebesar 0,983, diikuti oleh kelas *mentah* sebesar 0,959, kelas *setengah matang* sebesar 0,907, dan kelas *mengkal* sebesar 0,896. Nilai AUC yang mendekati 1 menunjukkan bahwa model memiliki tingkat sensitivitas dan spesifisitas yang tinggi dalam melakukan klasifikasi. Hasil ini mengindikasikan bahwa model CNN mampu mengenali perbedaan karakteristik visual antar kelas kematangan dengan cukup baik, meskipun masih terdapat tantangan pada kelas dengan karakteristik visual yang saling berdekatan

4.5 Hasil Prediksi Uji Citra

Untuk melihat kinerja model CNN secara visual, dilakukan pengujian prediksi terhadap beberapa citra uji yang mewakili masing-masing kelas tingkat kematangan buah nanas. Pengujian ini bertujuan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra secara langsung serta menampilkan tingkat kepercayaan model terhadap hasil prediksi yang dihasilkan.



Gambar 8. Hasil Pediksi Uji Kematangan Nanas

Berdasarkan hasil prediksi citra uji pada Gambar 8, model CNN mampu mengklasifikasikan tingkat kematangan buah nanas dengan tingkat kepercayaan yang tinggi. Dua citra uji pada gambar pertama dan kedua berhasil diklasifikasikan sebagai kelas *mengkal* dengan nilai probabilitas

sebesar 1,00, sedangkan citra ketiga diklasifikasikan sebagai kelas *mentah* dengan nilai probabilitas sebesar 0,95. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual utama pada buah nanas, terutama dominasi warna kulit dan tekstur permukaan buah, sehingga prediksi yang dihasilkan sesuai dengan kondisi tingkat kematangan citra uji. Tingginya nilai probabilitas pada hasil prediksi mengindikasikan bahwa model memiliki keyakinan yang kuat terhadap klasifikasi yang dihasilkan dan menunjukkan konsistensi performa model dalam mengklasifikasikan citra buah nanas secara visual.

Kebaruan (*novelty*) dari penelitian ini terletak pada pengembangan model Convolutional Neural Network (CNN) sederhana berbasis citra digital untuk mengklasifikasikan tingkat kematangan buah nanas menjadi empat kelas, yaitu *mentah*, *mengkal*, *setengah matang*, dan *matang*, melalui tahapan *preprocessing* dan *augmentasi* untuk meningkatkan variasi data. Selain itu, penelitian ini tidak hanya mengevaluasi performa model menggunakan *confusion matrix* dan metrik *precision*, *recall*, serta *f1-score*, tetapi juga menambahkan analisis ROC–AUC untuk melihat kemampuan diskriminasi model pada klasifikasi multikelas. Penelitian ini juga melakukan perbandingan dengan metode baseline Support Vector Machine (SVM) agar hasil yang diperoleh lebih objektif dan terukur sebagai dasar pengembangan sistem klasifikasi kematangan buah nanas secara otomatis.

5 KESIMPULAN

Berdasarkan hasil penelitian, model Convolutional Neural Network (CNN) yang dikembangkan mampu mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital menjadi empat kelas dengan akurasi sebesar 80%, Model yang dilatih selama 30 epoch menggunakan optimizer Adam dengan learning rate 0,001 menunjukkan kemampuan yang efektif dalam mengekstraksi fitur visual utama berupa warna dan tekstur kulit buah nanas. serta menunjukkan performa terbaik pada kelas *matang* dan *mentah*, sementara kesalahan klasifikasi masih dominan pada kelas *mengkal* dan *setengah matang* karena kemiripan karakteristik visual pada fase transisi kematangan. Meskipun akurasi SVM sedikit lebih tinggi dibanding CNN, CNN tetap memiliki keunggulan karena mampu mengekstraksi fitur citra secara otomatis (*end-to-end*) tanpa ekstraksi fitur manual. Hasil evaluasi menunjukkan CNN sudah mampu mengenali beberapa kelas dengan baik, namun kesalahan masih sering terjadi pada kelas yang memiliki kemiripan visual seperti *mengkal* dan *setengah matang*, sehingga performa CNN masih berpotensi ditingkatkan melalui optimasi pelatihan dan penerapan *transfer learning* pada penelitian selanjutnya

Untuk pengembangan selanjutnya, peningkatan dapat dilakukan tidak hanya melalui penambahan variasi data, tetapi juga dengan menerapkan *segmentasi objek* agar model fokus pada area buah, menggunakan penyesuaian strategi pelatihan seperti *early stopping* dan *learning rate scheduler* untuk mengurangi *overfitting*, serta mengadopsi *transfer learning* (misalnya *MobileNet/ResNet/EfficientNet*) agar ekstraksi fitur menjadi lebih kuat dan model lebih stabil saat diterapkan pada kondisi nyata.

REFERENSI

- [1] S. Juliansyah and A. D. Laksito, "Klasifikasi Citra Buah Pir Menggunakan Convolutional Neural Networks," vol. 11, no. 1, pp. 65–72, 2021.
- [2] A. F. Fuady, D. O. Amsyah, M. Farhan, R. Riansyah, and M. D. Dhiyaul, "Jurnal Publikasi Ilmu Komputer dan Implementasi Algoritma Convolutional Neural Network (CNN) untuk Pengenalan dan Klasifikasi Buah Berdasarkan Citra Digital".
- [3] L. 1.Kujur, V. Gupta, and A. Singhal, "A hybrid multi - optimizer approach using CNN and GB for accurate prediction of citrus fruit diseases," *Discov. Appl. Sci.*, 2025, doi: 10.1007/s42452-025-06593-2.
- [4] Y. A. Gerhana, R. R. Heryanto, and U. Syaripudin, "Implementation of Convolutional Neural Network CNN Algorithm to Detect Coffe Fruit Maturity," vol. 13, no. 2, pp. 47–50, 2024.

- [5] Y. Setiawan, W. Astuti, and M. R. R. Saelan, “Classification for Papaya Fruit Maturity Level With Convolutional Neural Network,” vol. 5, no. 3, 2023.
- [6] F. F. Maulana and N. Rochmawati, “Klasifikasi Citra Buah Menggunakan Convolutional Neural Network,” vol. 01, pp. 104–108, 2019.
- [7] N. Bacanin, T. Bezdán, and I. Strumberger, “Optimizing Convolutional Neural Network Hyperparameters by Enhanced Swarm Intelligence,” 2020, doi: 10.3390/a13030067.
- [8] N. 2 Sulistianingsih, F. Astutik, and A. Rahman, “Optimasi Seleksi Fitur Untuk Perbaikan Akurasi Support Vector Machine Classifier Pada Klasifikasi Citra Tanaman Rimpang,” *J. Fasilkom*, vol. 14, no. 2, pp. 526–532, 2024, doi: 10.37859/jf.v14i2.7566.
- [9] J. 5 Rusman, B. Z. Haryati, and A. Michael, “Optimisasi Hiperparameter Tuning pada Metode Support Vector Machine untuk Klasifikasi Tingkat Kematangan Buah Kopi,” *J. Komput. dan Inform.*, vol. 11, no. 2, pp. 195–202, 2023, doi: 10.35508/jicon.v11i2.12571.
- [10] S. Noris and A. Waluyo, “Penerapan Deep Learning untuk Klasifikasi Buah Menggunakan Algoritma Convolutional Neural Network (CNN),” vol. 6, no. 1, pp. 39–46, 2023, doi: 10.32493/jtsi.v6i1.29648.
- [11] I. Salamah, S. Humairoh, and S. Soim, “Implementasi Convolutional Neural Network Pada Alat Klasifikasi Kematangan dan Ukuran Buah Nanas Berbasis Android,” pp. 243–255, 2023.
- [12] L. W. 3 Rizkallah, “Optimizing SVM hyperparameters for satellite imagery classification using metaheuristic and statistical techniques,” *Int. J. Data Sci. Anal.*, vol. 20, no. 5, pp. 4945–4962, 2025, doi: 10.1007/s41060-025-00762-7.