

## KLASIFIKASI TINGKAT KEMATANGAN BUAH PISANG DENGAN ALGORITMA CNN

## CLASSIFICATION OF BANANA MATURITY LEVELS USING THE CNN ALGORITHM

<sup>1</sup>Amir Hamzah\*, <sup>2</sup>Renna Yanwastika Ariyana, <sup>3</sup>Untung Joko Basuki, <sup>4</sup>Muhammad Sholeh, <sup>5</sup>Bagas Tri Basgoro

<sup>1,2,3,4,5</sup>Universitas Akprind Indonesia

<sup>1\*</sup>[amir@akprind.ac.id](mailto:amir@akprind.ac.id), <sup>2</sup>[renna@akprind.ac.id](mailto:renna@akprind.ac.id), <sup>3</sup>[untungjb@akprind.ac.id](mailto:untungjb@akprind.ac.id), <sup>4</sup>[muhash@akprind.ac.id](mailto:muhash@akprind.ac.id),  
<sup>5</sup>[bagastri@akprind.ac.id](mailto:bagastri@akprind.ac.id)

Received:  
28 Juli 2025

Revised:  
19 August 2025

Accepted:  
24 November 2025

Published:  
6 Februari 2026

### ABSTRAK

Buah pisang merupakan buah yang paling banyak diproduksi di Indonesia, yaitu sekitar 9,69 juta ton pada tahun 2024. Dengan jumlah data tersebut menjadikan pisang memiliki nilai ekonomi yang cukup menjanjikan. Produksi pisang dalam jumlah besar sesuai data sebelumnya perlu dilakukan proses distribusi dengan cepat, karena waktu buah pisang setelah dipanen kemungkinan hanya dapat bertahan sekitar 5 sampai 7 hari dalam suhu normal sebelum akhirnya akan terjadi proses pembusukan buah. Untuk itulah perlu dilakukan proses klasifikasi buah pisang dengan cepat yang prosesnya dilakukan secara otomatis menggunakan mesin. Penelitian ini mengelaborasi kemampuan algoritma *CNN* dalam klasifikasi pisang. Dataset diambil dari sumber terbuka Keagle sebanyak 3000 data gambar. Dalam klasifikasinya peneliti membagi pisang dalam tiga tingkat kematangan buah, yaitu mentah, matang, dan terlalu matang. Penelitian menggunakan model *CNN* yang terdiri dari beberapa lapisan yang terdiri dari lapisan *konvolusi 2D (Conv2D)*, lapisan *pooling 2D (MaxPooling2D)*, lapisan *flatten*, lapisan *fully connected (Dense)*, dan lapisan *Dropout*. Setelah proses pembuatan model selesai, model akan diuji tingkat akurasi dengan metode *Confusion matrix*. Pada percobaan ke-3 model menghasilkan tingkat akurasi tertinggi dalam uji cobanya, dengan 300 gambar uji coba menghasilkan 290 gambar diprediksi dengan benar sehingga akurasinya mencapai 97%. Dari hasil *deploy* menggunakan antarmuka website dengan menggunakan *flask*, didapatkan klasifikasi memiliki akurasi di atas 95% sehingga cukup baik untuk dijadikan prototipe bagi aplikasi mesin klasifikasi.

**Kata Kunci :** buah pisang, algoritma CNN, klasifikasi, akurasi

### ABSTRACT

*Bananas are the most widely produced fruit in Indonesia, which is around 9.69 million tons in 2024. With this amount of data, bananas have quite promising economic value. The production of large quantities of bananas according to the previous data needs to be carried out a rapid distribution process, because the time the bananas after harvesting may only last about 5 to 7 days in normal temperatures before the fruit rotting process will finally occur. For this reason, it is necessary to carry out a quick banana classification process, the process is carried out automatically using a machine. This study elaborates on the capabilities of the CNN algorithm in the classification of bananas. Dataset was taken from Keagle's open source as many as 3000 image data. In their classification, researchers divided bananas into three levels of fruit ripeness, namely raw, ripe, and overripe. The study used a CNN model consisting of several layers consisting of a 2D convolutional layer (Conv2D), a 2D pooling layer (MaxPooling2D), a flatten layer, a fully connected layer (Dense), and a Dropout layer. After the model creation process is complete, the model will be tested for accuracy with the Confusion matrix method. In the 3rd experiment the model produced the highest level of accuracy in its trials, with 300 test images resulting in 290 correctly predicted images so that the accuracy reached 97%. From the results of deploying using the website interface using flask, it was found that the classification had an accuracy of above 95% so it was good enough to be used as a prototype for classification engine applications.*

**Keywords** : bananas, CNN algorithm, classification, accuracy

## PENDAHULUAN

Indonesia merupakan negara beriklim tropis, yang kaya akan sumber daya alam, terutama buah-buahan, terutama buah pisang. Pisang merupakan buah yang memiliki nilai ekonomi tinggi karena jumlah produksinya yang besar (Dipertan,2015; Yudha dan Noerbayinda,2023). Indonesia merupakan salah satu negara pemasok pisang segar dan kering ke berbagai negara seperti Singapura, Cina, Arab, Australia, Amerika Serikat dan negara lain (Ramadhani,2020). Menurut data dari Badan Pusat Statistik (BPS) pada tahun 2024 pisang menjadi buah yang paling banyak produksinya yaitu sekitar 9,69 juta ( [bps.go.id](https://bps.go.id), 2023). Namun potensi tersebut belum dapat dimanfaatkan secara maksimal untuk meningkatkan ekonomi Indonesia. Hal ini terutama berasal dari proses penanganan buah pisang yang belum tepat.

Produksi pisang dalam jumlah besar perlu dilakukan proses distribusi dengan cepat, karena waktu buah pisang setelah dipanen kemungkinan hanya dapat bertahan sekitar 5 sampai 7 hari dalam suhu normal. Namun sebelum proses tersebut dilakukan, diperlukan proses klasifikasi terlebih dahulu. Dengan jumlah buah yang sangat besar maka proses klasifikasi harus dilakukan secara otomatis menggunakan mesin untuk mempercepat prosesnya. Proses klasifikasi ini diperlukan untuk menentukan prioritas dalam distribusinya, sehingga kondisi buah akan lebih terjamin kesegarannya.

Dalam *machine learning* terdapat beberapa metode yang biasanya digunakan untuk proses klasifikasi. Metode yang sering digunakan dalam klasifikasi yaitu SVM (*Support Vector Machine*), KNN (*K-nearest neighbor*), dan CNN (*Convolutional Neural Network*). Dari penelitian sebelumnya menghasilkan pemrosesan data SVM dan KNN memiliki kecepatan yang lebih cepat dari CNN, namun dalam akurasi CNN memiliki akurasi lebih tinggi dibanding dengan kedua metode tersebut (A'yuni dan Hendrik, 2024).

Penelitian menggunakan metode CNN telah banyak dilakukan diberbagai bidang. Penelitian klasifikasi citra candi menggunakan CNN oleh Fajri dan Atika (2021), citra candi dibagi menjadi 3 kelas dengan inputgambar sebesar 64x64 dan 150x150. Sampel yang digunakan sebanyak 240 data. Jumlah data validasinya sebanyak 600 data dan ukuran *batch size* sebesar 32. Penelitian tersebut menggunakan model CNN dengan 2 proses konvolusi serta 2 proses pooling layer, masing masing proses konvolusi digunakan aktivasi fungsi RELU. Hasil penelitian tersebut menghasilkan tingkat akurasi 92%. Penelitian klasifikasi jamur menggunakan CNN dilakukan oleh Octaviana (2020). Peneliti menggunakan gambar untuk setiap kategori data sebanyak 260 dari masing-masing jenis jamur dengan perbandingan datanya 80% (*training*) : 20% (*validation*). Dalam tahap klasifikasi menggunakan 3 *optimizer* berbeda dengan menghasilkan akurasi Adam 62% dengan *epoch* 100, RMSProp dengan *epoch* 50 menghasilkan akurasi 54%, dan SGD dengan *epoch* 50 menghasilkan akurasi 55%. Penelitian menggunakan metode CNN dengan menggunakan objek buah nanas dilakukan Purba dkk (2022). Penelitian tersebut menghasilkan akurasi tertinggi sampai 86% dan terendahnya yang didapat yaitu 80% dengan rata-rata akurasi sebesar 83,33%. Dataset dalam penelitian tersebut berisi 150 gambar yang masing-masing klasifikasi terdiri dari 50 gambar.

Buah lain yang dijadikan objek yang dilakukan dalam penelitian sebelumnya yang juga menggunakan metode CNN yaitu buah jeruk. Klasifikasi buah jeruk manis ini dilakukan berdasarkan tingkat kecerahan warnanya. Pada penelitian tersebut jumlah dataset yang digunakan yaitu dengan 100 data gambar jeruk manis. Tingkat akurasi dari proses klasifikasi sebesar 97,5184% dilakukan klasifikasi hasilnya sebesar 67,8221%. Pengujian dilakukan dengan menggunakan 10 gambar jeruk yang terbagi menjadi 5 gambar jeruk bagus dan 5 gambar jeruk busuk, hasilnya yaitu *training* 96% dan *testing* 92%, hasil tersebut dinilai telah berhasil dengan cukup bagus (Yanto, 2021).

Klasifikasi lain dengan objek buah yaitu menentukan tingkat kematangan buah mangga Badami. Citra buah mangga Badami diambil dari repositori Kaggle, totalnya sebanyak 204 gambar. Gambar terdiri dari 34 mangga Badami busuk, 75 mangga Badami mentah serta 95 mangga Badami matang. Data dibagi menjadi 179 data *training* dan 25 data *testing*. Pengujian menghasilkan akurasi *training* sebesar 97,2% dan untuk akurasi data *testing* menghasilkan 94,6 (Arkadia dkk,2021).

Dalam analisis perbandingan algoritma SVM, KNN, dan CNN untuk klasifikasi citra cuaca, algoritma CNN mempunyai akurasi tertinggi diantara algoritma lainnya. Dataset dalam penelitian tersebut berisi gambar sebanyak 1120 dan terbagi menjadi 4 kelas, yaitu *Cloudy*, *Rain*, *Shine*, dan *Sunrise*. Meski dalam proses *training* CNN memerlukan proses paling lama namun akurasi lebih tinggi dibanding lainnya yaitu dengan akurasi sebesar 94% (Naufal, 2021). Hasil yang sama, yang menunjukkan CNN lebih unggul adalah penelitian Abdurrahman dkk (2023).

Berdasarkan penelitian sebelumnya, peneliti melakukan perancangan model *machine learning* dengan menerapkan metode CNN serta menggunakan *Adam* sebagai *optimizer* nya. Tabel 1 hasil perbandingan metode yang digunakan sebelumnya.

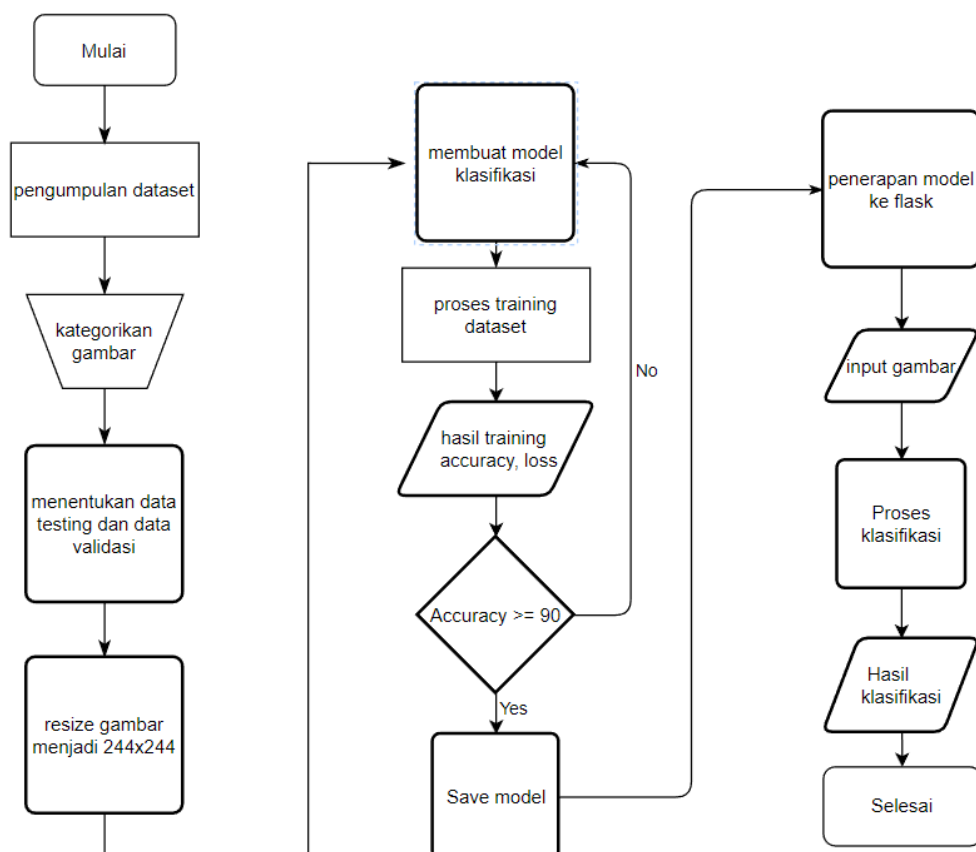
**Tabel 1. Perbandingan Metode Klasifikasi CNN**

No	Obyek	Metode	Sampel	Optimizer	Akurasi
1	Candi[5]	CNN	840	Adam	92 %
2	Jamur[6]	CNN	780	Adam	62 %
				RMSprop	54 %
				SGD	55 %
3	Nanas[7]	CNN	150		86 %
4	Jeruk[8]	CNN	100		92 %
5	Manga Badamim[9]	CNN	204		94 %
6	Citra cuaca [10]	SVM	1120	Adam	76 %
		KNN			86 %
		CNN			94%

Rumusan permasalahan dalam penelitian ini adalah bagaimana menentukan model terbaik untuk mengklasifikasikan gambar buah pisang menggunakan metode *Convolutional Neural Network (CNN)* dan menampilkan aplikasi web untuk klasifikasi buah pisang . Adapun tujuan dari penelitian ini adalah menentukan model terbaik klasifikasi menggunakan metode *Convolutional Neural Network (CNN)* dan membuat prototipe aplikasi website menggunakan *flask*.

#### METODE

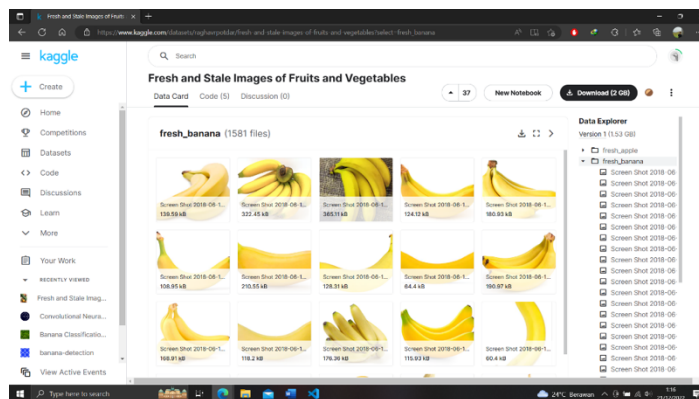
Dalam penelitian ini, ditempuh beberapa tahapan dengan tiap tahapan memiliki tujuan yang berbeda dalam proses penelitian yang sedang dijalankan. Adapun tahapan penelitian disajikan dalam gambar 1.



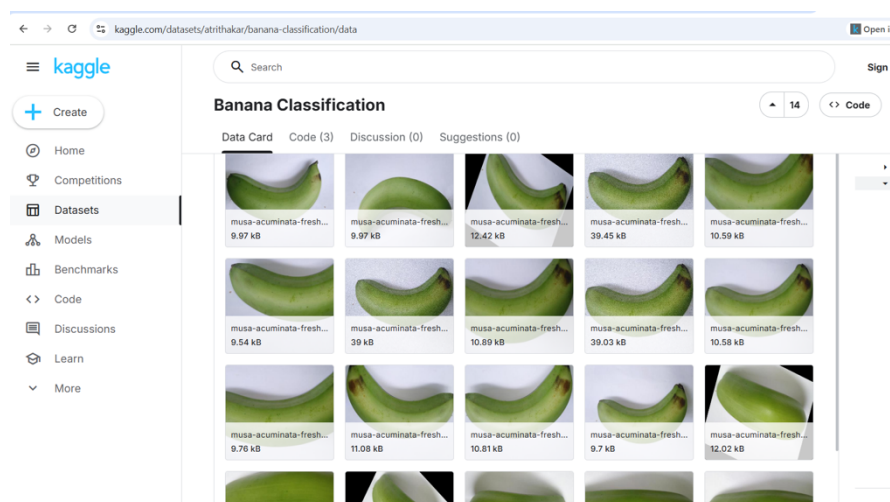
Gambar 1. Langkah-langkah penelitian

### Dataset

Langkah penelitian pertama adalah persiapan dataset dan pengkategorian data. Dataset diambil dari *Kaggle* berisi folder gambar pisang matang, mentah, dan terlalu matang yang digunakan untuk proses *training* dan *test*. Untuk data pisang matang dan terlalu matang diambilkan dari ([Kaggle.com](https://www.kaggle.com/atrishakar/fresh-and-stale-images-of-fruits-and-vegetables), 2023) , sedangkan untuk data pisang mentah diambilkan dari ([Kaggle.com](https://www.kaggle.com/atrishakar/banana-classification), 2024). Halaman sumber data disajikan dalam gambar 2 dan gambar 3. Setelah proses selesai gambar akan dikompres menjadi format zip untuk mempercepat proses unduhnya. Setelah semua data diperoleh maka akan langsung dikategorikan berdasarkan kategorinya.



Gambar 2. Halaman Kaggle dataset pisang matang dan terlalu matang ([Kaggle.com](https://www.kaggle.com/atrishakar/fresh-and-stale-images-of-fruits-and-vegetables), 2023)



Gambar 3. Halaman Kaggle dataset pisang mentah ([Kaggle.com](https://www.kaggle.com/atrishakar/banana-classification), 2024)

Selanjutnya untuk data test peneliti melakukan *scrapping image from bing* untuk mendapatkan 3000 data gambar. Penelitian ini terdapat 3 kategori yaitu kategori matang, mentah, dan terlalu matang. Masing-masing kategori terdapat 1000 gambar, 100 gambar digunakan untuk data *test* , 720 gambar digunakan sebagai data *training*, 180 gambar digunakan untuk data *validasi*. Ukuran data gambar pisang yang digunakan cukup beragam, ukuran terkecil data gambar pisang yang digunakan yaitu 200x133 piksel sampai ukuran 1600x1200 piksel.

### Pembuatan Model

Langkah yang kedua adalah membuat model dengan melakukan pelatihan (*training*) dan pengujian (*testing*). Pembuatan model *machine learning* menggunakan algoritma CNN dengan total 8 *layer*, dengan 3 *layer convolutional*, 3 *layer pooling*, 1 *layer flatten*, dan *layer fully connected*. Proses *training* dilakukan per-*batch* dengan ukuran *batch size* 60, 90 dan 108. Percobaan pelatihan model dilakukan sebanyak 3 kali, dengan rincian 20 *epoch*, 30 *epoch* dan 50 *epoch*. . Setelah proses training selesai peneliti

menggunakan *confusion matrix* untuk mengukur performa modelnya. *Confusion matrix* merupakan salah satu metode yang digunakan untuk mengukur *Recall*, *Precision*, dan skor F1 yang digunakan untuk mengevaluasi kinerja model klasifikasi.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 4 Confusion matrix

Keterangan:

- TP : Kelas positif yang diprediksi positif.
- TN : Kelas positif yang diprediksi negatif.
- FP : Kelas negatif yang diprediksi positif.
- FN :Kelas negatif yang diprediksi negatif.

Berikut istilah dan rumus yang digunakan untuk mencari nilai dalam metode *Confusion Matrix*:

*Recall* merupakan proporsi kasus positif yang secara aktual teridentifikasi. Rumus untuk mengetahui *recall* yaitu:

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

*Precision* merupakan proporsi kasus dengan hasil positif yang benar.

Rumus dari *Precision* yaitu:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

*Accuracy* adalah perbandingan kasus yang diidentifikasi benar dengan jumlah semua kasus. Rumus dari *accuracy* yaitu:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

Skor F1 adalah rata-rata presisi dan recall yang harmonis. Metrik skor F1 digunakan saat Anda mencari keseimbangan antara presisi dan perolehan. Rumus dari skor F1 yaitu:

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

Nilai akurasi diperlukan untuk menentukan apakah model yang dibuat sudah cukup akurat atau belum dalam klasifikasinya. Dalam penelitian ini peneliti menetapkan target *Accuracy* sebesar  $\geq 90\%$  jika belum mencapai target peneliti akan memperbaiki lagi model yang telah dirancang

#### *Penerapan Model*

Langkah terakhir adalah penerapan model pada flask. *Flask* adalah sebuah web *framework* yang ditulis dengan bahasa *Python* dan tergolong sebagai jenis *microframework*. *Flask* berfungsi sebagai kerangka kerja aplikasi dan tampilan dari suatu web. *Flask* memiliki fleksibilitas cukup tinggi dibandingkan dengan *framework* lainnya (Maulid,2021).

## HASIL DAN PEMBAHASAN

Hasil penelitian dan pembahasan dapat diuraikan sebagai berikut.

### Hasil Penelitian

Model *machine learning* menggunakan algoritma CNN dengan total 8 *layer*, dengan 3 *layer convolutional*, 3 *layer pooling*, 1 *layer flatten*, dan *layer fully connected*.

```
[ ] from keras.models import Sequential
from keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout, GlobalAveragePooling2D, BatchNormalization
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.utils import plot_model

def custom_model():
    model = Sequential()

    model.add(Conv2D(16, (3,3), activation='relu', padding='same', input_shape=(224, 224, 3)))
    model.add(MaxPooling2D(pool_size=(2, 2)))
    model.add(Conv2D(32, (3,3), activation='relu', padding='same'))
    model.add(MaxPooling2D(pool_size=(2, 2)))
    model.add(Conv2D(64, (3,3), activation='relu', padding='same'))
    model.add(MaxPooling2D(pool_size=(2, 2)))

    model.add(Flatten())

    model.add(Dense(128, activation='relu'))
    model.add(Dropout(0.2))

    model.add(Dense(3, activation='softmax'))

    opt = Adam(learning_rate=0.00001)
    model.compile(optimizer=opt, loss='categorical_crossentropy', metrics=['accuracy'])
    return model

model = custom_model()

model.summary()
```

Gambar 5. Kode Python untuk definisi model CNN

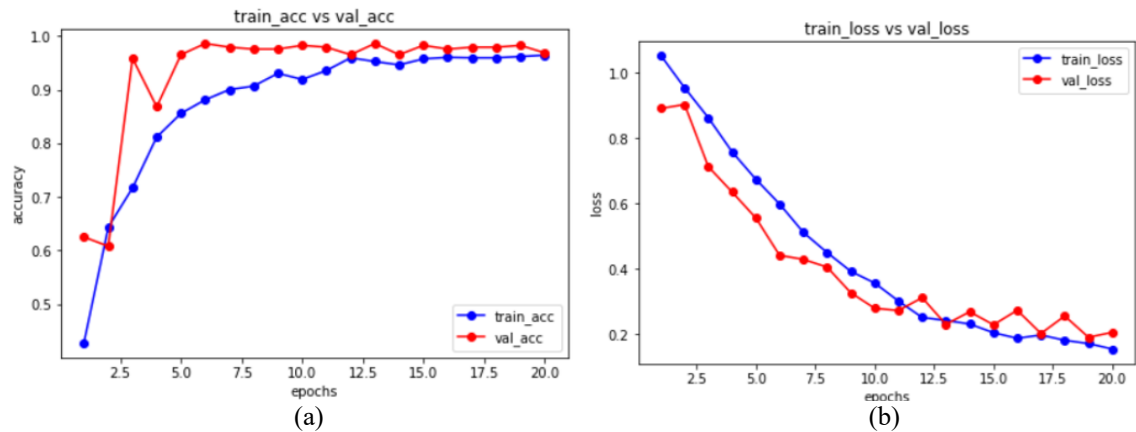
Model CNN tersebut menghasilkan 6.446.627 parameter. Parameter dalam *CNN (Convolutional Neural Network)* adalah nilai yang digunakan untuk menentukan kinerja dari jaringan tersebut. Parameter-parameter tersebut meliputi bobot dan bias dari setiap lapisan jaringan, serta nilai-nilai yang digunakan dalam proses konvolusi dan pooling.

Pembagian untuk dataset yang dimiliki, yaitu 3000 data gambar adalah seperti pada tabel 2 berikut.

**Tabel 2. Pembagian dataset untuk Training, Validasi dan Testing**


No	Kategori	train	validasi	test	Total
1	Matang	720	180	100	1000
2	Mentah	720	180	100	1000
3	Terlalu Matang	720	180	100	1000
		2160	540	300	3000

Proses *training* dilakukan per-*batch* dengan ukuran *batch\_size* 60,90 dan 108 *batch*. Percobaan pelatihan model dilakukan sebanyak 5 kali, dengan rincian 10, 20,30, 40 dan 50 *epoch*. Pada setiap percobaan dicatat waktu eksekusi, akurasi dari training dan validation, serta *loss* dari *training* dan *validation*. Untuk percobaan pertama (20 *epoch*) membutuhkan waktu 1 jam 17 menit 17 detik dan model terbaiknya menghasilkan *train\_loss* 0.1719, *train\_acc* 0.918, *val\_loss* 0.1909 dan *val\_accuracy* 0.9826. Grafik training dan validation *accuration* dan *loss* disajikan dalam gambar 6 (a) untuk *accuration* dan (b) untuk *loss*



Gambar 6. Training dan validation untuk 20 epoch: (a) accuracion (b) loss

Percobaan ketiga (50 epoch 60 batch) merupakan percobaan dengan waktu paling lama dan memiliki akurasi paling baik. Percobaan membutuhkan waktu 3 jam 2 menit 40 detik dan menghasilkan *train\_loss* 0.077, *train\_acc* 0.982, *val\_loss* 0.080 dan *val\_accuracy* 0.9757. Grafik training dan validation *accuration* dan loss disajikan dalam gambar 7 (a) *accuracion* dan 7 (b) untuk loss



Gambar 7. Training dan validation untuk 50 epoch: (a: *accuracion*; (b) loss

Untuk seluruh percobaan dengan semua jumlah *epoch* dan *batch* yang dicobakan, ringkasan hasilnya disajikan dalam Tabel 3.

**Tabel 3. Ringkuman Hasil *Training Model***

Percobaan	Waktu		Hasil		
	jam:mnt:det	Accuracy	loss	Val acc	Val loss
Perc-1:20 epc 60 btc	1:17:17	0.918	0.172	0.9826	0.1909
Perc-2:30 epc 60 btc	1:54:33	0.969	0.147	0.9688	0.1574
Perc-3:50 epc 60 btc	3:02:40	<b>0.982</b>	<b>0.077</b>	0.9757	0.0804
Perc-4:50 epc 90 btc	2:08:20	0.973	0.136	0.9792	0.0658
Perc-5:50 epc 108 btc	1:47:15	0.953	0.169	0.9688	0.1355

*Pembahasan*


Dalam proses training sebanyak 5 kali percobaan didapatkan percobaan ke-3 dengan 50 *epoch* 60 *batch* memiliki akurasi paling tinggi, yaitu 0,982 dengan loss 0.077, meskipun membutuhkan waktu eksekusi yang paling lama, yaitu lebih dari 3 jam.

Hasil model dari training tersebut kemudian dilakukan testing menggunakan 300 objek data testing dengan masing-masing klas sebanyak 100 objek. Setiap percobaan dihitung akurasinya menggunakan confusion matrix. Untuk percobaan ke-2 hasil rata-rata akurasi berdasarkan confusion matrix adalah 0.95 seperti pada gambar 8.

Classification Report				
	precision	recall	f1-score	support
matang	1.00	0.90	0.95	100
mentah	0.97	0.95	0.96	100
terlalu matang	0.89	1.00	0.94	100
accuracy			0.95	300
macro avg	0.95	0.95	0.95	300
weighted avg	0.95	0.95	0.95	300

Gambar 8. Hasil klasifikasi (percobaan ke-2)

Grafik dari confusion matrix untuk percobaan 2 disajikan dalam gambar 9. Terlihat bahwa untuk objek gambar pisang yang terlalu matang memiliki akurasi paling tinggi, yaitu 100%.



Gambar 9. Hasil klasifikasi (percobaan ke-2)

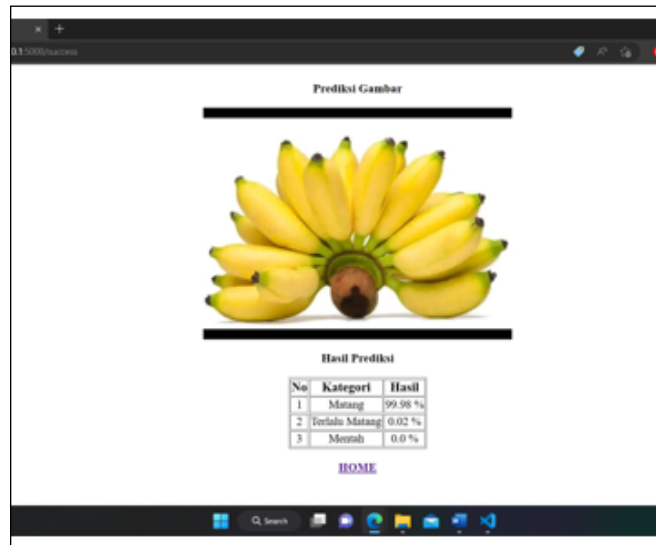
Rangkuman pengujian (testing) dalam 5 kali percobaan didapatkan hasil akurasi seperti pada Tabel 4 berikut.

**Tabel 4. Akurasi data testing semua percobaan**

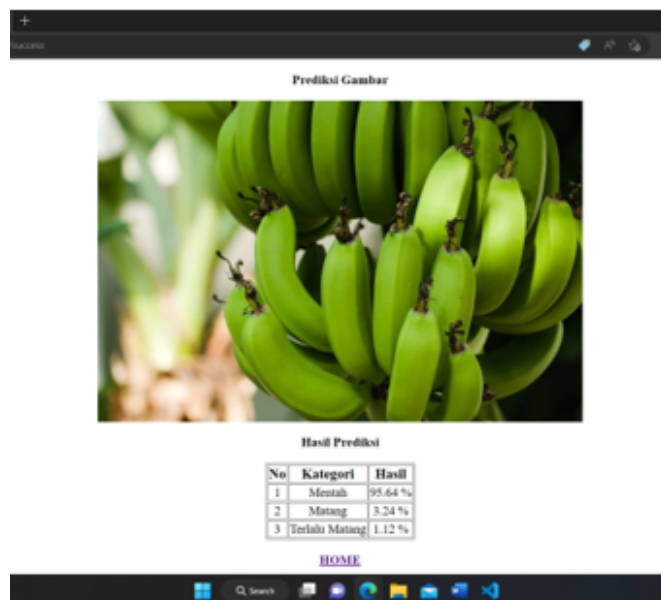
Percobaan	Hasil ( <i>true</i> )			Akurasi
	Matang	Mentah	Terlalu Matang	
Percob-1	92	93	100	285/300 = 0.95
Percob-2	90	95	100	285/300 = 0.95
Percob-3	93	97	100	290/300 = <b>0.97</b>
Percob-4	94	93	100	287/300 = 0.96
Percob-5	91	91	100	282/300 = 0.94

Dari tabel 4 didapatkan akurasi tertinggi mencapai 97%. Dari tabel tersebut juga terlihat bahwa pada klas objek “Terlalu matang” dapat mencapai akurasi 100%.

Langkah terakhir adalah melakukan deploy algoritma dengan menggunakan flask. Hasil deteksi klas dengan cara memberikan gambar objek pisang maka sistem akan mengenali dengan memberikan prosesntase kemungkinan untuk setiap klas. Misalnya untuk mendeteksi pisang matang dan mentah disajikan dalam gambar 10 dan gambar 11 berikut.



Gambar 10. Prediksi objek gambar pisang matang



Gambar 11. Prediksi gambar pisang mentah

Dari deploy algoritma untuk memprediksi gambar didapatkan akurasi di atas 95%. Akurasi tersebut melebihi beberapa penelitian menggunakan algoritma CNN pada klasifikasi buah yang telah dilakukan penelitian sebelumnya.

## KESIMPULAN

Penelitian ini telah berhasil membuat model CNN untuk klasifikasi kematangan buah pisang sehingga dapat digunakan untuk klasifikasi. Pembuatan model menggunakan 3 *layer convolutional*, 3 *layer pooling*, 1 *layer flatten*, dan *layer fully connected*. Tingkat akurasi dalam *Confusion matrix* sudah cukup tinggi dalam uji cobanya, dengan 300 gambar uji coba menghasilkan 290 gambar diprediksi dengan benar sehingga akurasinya mencapai 97%. Pembuatan model berhasil sehingga tersimpan kedalam file dengan format hdf5. Hasil model yang tersimpan dapat di-deploy dengan baik di flask.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terimakasih kepada semua pihak yang telah membantu terselesainya penelitian ini, utamanya kepada laboratorium jurusan Informatika Universitas Akprind Indonesia.

## DAFTAR PUSTAKA

- A'yuni,Q., and Hendrik,B. (2024). Literature Review: Analisis Komparatif Algoritma CNN, KNN, dan SVM untuk Klasifikasi Penyakit Kelapa Sawit”, *Journal of Education Research*, 5(4), 6589-6596
- Abdurrahman,N.,Rahmat,B.,Sihananti,A.N.(2023).Perbandingan Performa Klasifikasi Citra Ikan Menggunakan Metode K-Nearest Neighbor (K-NN) Dan Convolutional Neural Network (CNN). *Jurnal Sistem Informasi dan Informatika*, 2(2),84-93.
- Arkadia,A., S. A. Damayanti, and D. S. Prasvita. (2021). Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN,” *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, 8(1),158–165.
- Bps.go.id., <https://www.bps.go.id/id/statistics-table/2/NjIjMg==/produksi-tanaman-buah-buahan.html>  
Dipertan (Dinas Pertanian Kabupaten Buleleng. (2015). <https://distan.bulelengkab.go.id/informasi/detail/artikel/kultur-jaringan-pada-pisang-35>, (accessed Aug. 25, 2023
- Fajri,R. dan Atika,L. (2021). Implementasi Machine Learning Dengan Menggunakan Cnn (Convolutional Neural Network) Untuk Klasifikasi Citra Candi. *Bina Darma Conf. Comput. Sci.*, pp. 317–323.
- Kaggle.com (2023). [https://www.kaggle.com/datasets/raghavrpotdar/fresh-and-stale-images-of-fruits-and-vegetables?select=fresh\\_banana](https://www.kaggle.com/datasets/raghavrpotdar/fresh-and-stale-images-of-fruits-and-vegetables?select=fresh_banana)
- Kaggle.com.(2024). <https://www.kaggle.com/datasets/andrreuzcalle/banana-classification-dataset>.
- Maulid,R. (2021). Mengenal Flask, Library Machine Learning Python Idaman Developer. <https://dqqlab.id/mengenal-flask-library-machine-learning-python-idaman-developer>
- Naufal,N.F. (2021). Comparative Analysis of Image Classification Algorithm for,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 2, pp. 311–318, 2021, doi: 10.25126/jtiik.202184553.
- Ocktavia N. P.(2020). Implementasi Metode CNN Dalam Klasifikasi Gambar Jamur Pada Analisis Image Processing (Studi Kasus: Gambar Jamur Dengan Genus Agaricus Dan Amanita). [Online]. Available: <https://dSPACE.uui.ac.id/bitstream/handle/123456789/23677/16611103%20Ocktavia%20Nurima%20Putri.pdf?sequence=1&isAllowed=y>
- Purba,YBE, N. F. Saragih, A. P. Silalahi, and S. Sitepu. 2022. Perancangan Alat Pendeteksi Kematangan Buah Nanas Dengan Menggunakan Mikrokontroler Dengan Metode Convolutional Neural Network ( CNN ), 2(1), 13–21.
- Ramadhani,S.U.N. (2020). Analisis Trend Konsumsi Buah-Buahan Segar Di Kota Makassar,” *Skripsi, Universitas Muhammadiyah Makassar*.
- Yanto,B., Fimawahib, L , Supriyanto, B. H. Hayadi, and R. R. Pratama.(2021). Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network. *INOVTEK Polbeng - Seri Inform.*, 6(2), 259, 2021
- Yudha,E.P. dan Noerbayinda, E. (2023), Analisis Daya Saing Pisang Indonesia Ke Negara Tujuan Ekspor Serta Faktor-Faktor Yang Mempengaruhinya, *Jurnal Ekonomi Pertanian dan Agribisnis (JEPA)*, 7(1) 146-154