

Identifikasi Varietas Jagung Menggunakan Metode Convolutional Neural Network

Abdurrahim Ramadhan Idin^{a1}, Aziz Kustiyo^{b2}, Muhammad Asyhar Agmalaro^{b3}, Toto Haryanto^{a4}

^aComputer Science Study Program, School of Data Science, Mathematics and Informatics,
IPB University
Jl. Raya Dramaga, Kampus IPB Dramaga Bogor, West Java, Indonesia
¹webzzkunabdurrahim@apps.ipb.ac.id
⁴totoharyanto@apps.ipb.ac.id

^bArtificial Intelligence Study Program, School of Data Science, Mathematics and Informatics,
IPB University
Jl. Raya Dramaga, Kampus IPB Dramaga Bogor, West Java, Indonesia
²azizku@apps.ipb.ac.id (Corresponding author)
³agmalaro@apps.ipb.ac.id

Abstract

Corn is one of Indonesia's primary commodities, but its productivity is significantly affected by environmental and climatic conditions. Crop yields often fluctuate due to climate change, particularly the El Niño phenomenon, which can lead to drought and delays in planting seasons. As a result, selecting superior drought-resistant seeds is essential, especially in dryland areas like East Nusa Tenggara. Traditional methods for identifying seeds, such as manual morphological measurements, are considered inefficient in terms of time and labor. This study aims to develop a corn seed variety classification system using a Convolutional Neural Network that focuses on five varieties: NK 212, NK 7328 Sumo, P 21, Pertiwi 2, and Pertiwi 6. We designed and tested three CNN architectures with varying complexities. The most effective model, which includes three convolutional layers and two fully connected layers with dropout, achieved an optimal performance of 89,20% accuracy on the test data.

Keywords: Image Processing, Drought Stress, Convolutional Neural Network, Seed Identification, Corn

1. Pendahuluan

Pertanian memiliki peran penting dalam keberlangsungan hidup manusia, terutama dalam hal ketahanan pangan dan perekonomian. Di Indonesia, jagung menjadi salah satu komoditas yang berkontribusi besar dalam memenuhi kebutuhan pangan nasional. Namun, menurut penelitian Irawan [1], jagung termasuk komoditas yang paling rentan terhadap dampak perubahan iklim. Laporan kinerja Kementerian Pertanian tahun 2023 [2] juga menunjukkan adanya fluktuasi produksi jagung dalam beberapa tahun terakhir. Pada tahun 2023, produksi jagung tercatat sebesar 19,56 juta ton, mengalami penurunan 12,5% dibandingkan dengan tahun sebelumnya yang mencapai 22,36 juta ton. Penurunan ini dipengaruhi oleh fenomena El Niño yang memicu kekeringan, sehingga menyebabkan keterlambatan musim tanam akibat minimnya ketersediaan air.

Untuk meningkatkan produktivitas jagung, pemilihan benih unggul yang tahan terhadap kekeringan sangat penting, terutama di daerah lahan kering seperti Nusa Tenggara Timur (NTT). Penelitian oleh Sitorus et al. [3] menunjukkan bahwa varietas Nasa 29, Pertiwi 6, NK 7328 Sumo, JH 27, dan Pertiwi 5 memiliki performa yang baik dalam kondisi lahan kering di NTT, dengan produktivitas dan ketahanan yang lebih tinggi terhadap cekaman lingkungan. Sebaliknya, varietas seperti NK 212, Pertiwi 2, Pioneer P 21, JH 37 dan JH 45 menunjukkan hasil yang kurang optimal dan adaptasi yang terbatas dalam kondisi tersebut.

Salah satu metode yang sering digunakan dalam pemilihan benih adalah analisis karakteristik morfologi benih, seperti ukuran, warna, area, dan bentuk benih. Namun, pengukuran manual atas ciri-ciri ini membutuhkan waktu yang signifikan serta ketersediaan tenaga ahli. Metode manual juga rentan terhadap inkonsistensi dan kesalahan manusia, sehingga berpotensi menghasilkan pemilihan

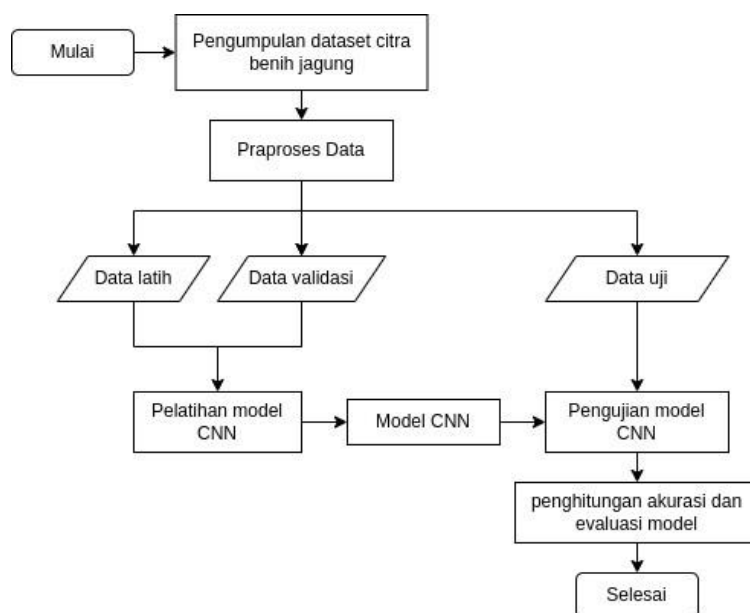
benih yang tidak optimal. Di samping itu, pengetahuan terhadap benih tersebut juga diperlukan untuk menghindari adanya benih palsu [4]. Berdasarkan informasi dari media online [5], kasus pemalsuan benih jagung pernah terungkap di Jawa Timur dengan kerugian yang cukup besar. Sindikat pemalsu merek benih jagung berhasil memproduksi 5.500 sak benih palsu siap edar, menyebabkan kerugian ekonomi mencapai Rp 5 miliar. Selain kerugian tersebut, benih palsu memiliki potensi memperparah risiko gagal panen.

Penelitian terkait klasifikasi dan identifikasi varietas tanaman menggunakan metode *Convolutional Neural Network* (CNN) telah menunjukkan hasil yang baik dalam berbagai aplikasi pertanian. Sebagai contoh, Nugroho dan Sebatubun [6] berhasil mengklasifikasikan varietas kopi arabika dengan akurasi 86% melalui analisis fitur morfologi biji kopi mentah menggunakan CNN, *Gray Level Co-occurrence Matrix* (GLCM), dan *Support Vector Machine* (SVM). Ardianto dan Wibisono [7] mengembangkan metode klasifikasi varietas gandum dengan arsitektur CNN MobileNet dan mencapai akurasi hingga 98%. Untuk klasifikasi varietas jagung, Chandra et al. [8] menggunakan metode *K-Nearest Neighbor* (K-NN) untuk mengklasifikasikan varietas jagung mutiara dengan akurasi 93,24%.

Berdasarkan uraian di atas, penelitian ini mengusulkan metode CNN untuk mengotomatisasi proses identifikasi, meningkatkan akurasi, dan mengurangi ketergantungan pada tenaga ahli. Tujuan dari penelitian ini adalah mengembangkan model CNN yang dapat mengidentifikasi varietas jagung berdasarkan citra digital.

2. Metode Penelitian

Tahapan penelitian disajikan pada Gambar 1. Penelitian ini diawali dengan pengumpulan dataset citra benih jagung dari lima varietas. Dalam setiap citra tersebut terdapat 16 benih jagung dengan latar belakang berwarna hitam. Selanjutnya dilakukan praproses data untuk menambah variasi dataset. Tahapan berikutnya adalah membagi data menjadi data latih, data validasi dan data uji. Data latih dan data validasi digunakan dalam proses pelatihan model CNN. Terdapat tiga model CNN yang dibangun dalam penelitian ini. Setelah dilatih, model CNN diuji menggunakan data uji. Kinerja model CNN tersebut kemudian dievaluasi menggunakan *confusion matrix*. Berdasarkan matrik tersebut, dihitung akurasi, *precision*, *recall*, dan *F1-score* hasil pengujian model CNN. Selain itu, matrik tersebut juga digunakan untuk mengetahui kesalahan prediksi setiap varietas.




Gambar 1. Tahapan penelitian Identifikasi Varietas Jagung menggunakan CNN

2.1. Pengumpulan Dataset Citra Benih Jagung

Benih dari lima varietas jagung yang digunakan dalam penelitian ini didasarkan pada penelitian Sitorus et al. [3]. Dua varietas jagung memiliki rasio *Benefit/Cost* (rasio B/C) lebih dari 2,0, mewakili benih dengan produktivitas dan ketahanan yang lebih tinggi terhadap cekaman lingkungan yang

direkomendasikan untuk ditanam di NTT yaitu varietas Pertiwi 6 dan NK 7328 Sumo. Tiga varietas yang lain yaitu Pioneer P 21, NK 212 dan Pertiwi 2 memiliki rasio B/C kurang dari 2,0 tidak termasuk varietas jagung yang direkomendasikan ditanam di NTT. Rasio B/C dari NK-212 dan Pertiwi-2 berturut-turut adalah 1,48 dan 1,50.

Pengumpulan data benih jagung akan melibatkan 2500 citra yang diambil dari kelima varietas tersebut. Setiap varietas akan diwakili oleh 500 citra, yang diambil menggunakan kamera digital dengan resolusi 50 MP. Pengambilan citra dilakukan dengan jarak sekitar 25 cm dari benih jagung dengan latar belakang hitam. Pemilihan latar belakang ini bertujuan untuk meningkatkan kontras antara benih dan latar, mempermudah proses ekstraksi fitur pada tahap berikutnya. Ilustrasi penyusunan benih jagung untuk proses akuisisi citra disajikan pada Gambar 2, dengan latar belakang berwarna hitam dan benih jagung berwarna jingga sebanyak 16 benih. Penyusunan benih seperti pada Gambar 2 dimaksudkan agar diperoleh lebih banyak citra benih jagung dibandingkan dengan pengambilan citra untuk setiap benih jagung.



.Gambar 2. Ilustrasi penyusunan benih jagung

2.2. Praproses Data

Tahapan praproses dilakukan untuk mempersiapkan data sebelum proses pelatihan model CNN, dengan tujuan meningkatkan kualitas dan variasi dataset sehingga model dapat belajar lebih efektif dan *robust* terhadap variasi input. Pada tahap ini, beberapa teknik augmentasi diterapkan, seperti *rescale* untuk menormalisasi nilai piksel, rotasi, pergeseran horizontal dan vertikal, penyesuaian kecerahan, serta *zoom* untuk memperkaya variasi data. Selain itu, dilakukan juga *flipping* untuk menambah keragaman sudut pandang citra. Teknik-teknik tersebut bertujuan untuk meningkatkan generalisasi model. Detail parameter augmentasi disajikan pada Tabel 1.

Table 1. Detail parameter augmentasi

Parameter	Nilai/Rentang	Keterangan
<i>Rotation Range</i>	45 derajat	Rentang rotasi citra.
<i>Width Shift Range</i>	0,1	Rentang pergeseran horizontal.
<i>Height Shift Range</i>	0,1	Rentang pergeseran vertikal.
<i>Brightness Range</i>	[0,9-1,1]	Rentang penyesuaian kecerahan.
<i>Zoom Range</i>	0,1	Rentang <i>zoom</i> citra.
<i>Flip</i>	True	Membalik citra

2.3. Pelatihan Model CNN

Lee dan Song [9] menjelaskan bahwa struktur umum CNN untuk tugas klasifikasi terdiri dari satu atau lebih lapisan konvolusi dan *pooling* yang disusun secara bergantian. Fitur-fitur yang dihasilkan dari blok-blok ini kemudian diratakan (*flattened*) dan dihubungkan dengan semua node pada lapisan *neural network* selanjutnya yang disebut *fully-connected* untuk melakukan klasifikasi.

Pelatihan model dilakukan menggunakan arsitektur CNN yang dirancang secara manual, terdiri dari lapisan konvolusi, *max pooling*, dan *fully connected*. Pada lapisan konvolusi dan *fully connected* digunakan fungsi aktivasi ReLU (*Rectified Linear Unit*). Fungsi ReLU dipilih karena kemampuannya dalam mengatasi masalah *vanishing gradient* [10]. Setelah lapisan konvolusi, lapisan *max pooling* ditambahkan untuk mengurangi dimensi spasial citra tanpa menghilangkan fitur penting yang telah terekstraksi sebelumnya. Lapisan output menggunakan fungsi aktivasi *softmax* untuk menghasilkan probabilitas distribusi kelas.

Pada penelitian ini dilakukan tiga eksperimen dengan arsitektur CNN yang berbeda untuk klasifikasi varietas benih jagung. Setiap model memiliki perbedaan pada lapisan konvolusi dan *fully connected*, yang diberi label Model_1, Model_2, dan Model_3. Model_1 menggunakan arsitektur sederhana

dengan 2 lapisan konvolusi dan 1 lapisan *fully connected (dense)*. Pada Model_2 ditambahkan 1 lapisan konvolusi untuk menambah kedalaman model sehingga arsitektur Model_2 menggunakan 3 lapisan konvolusi dan 1 lapisan *fully connected*. Model_3 menggunakan arsitektur yang lebih dalam dengan 3 lapisan konvolusi dan 2 lapisan *fully connected*, serta penambahan *dropout* untuk mengurangi overfitting. Berdasarkan penelitian Josephine et al. [11], penambahan *hidden dense layer* dapat meningkatkan akurasi CNN, oleh karena itu pada penelitian ini digunakan beberapa *dense layer*. Detail arsitektur ketiga model tersebut disajikan pada Tabel 2.

Data yang digunakan untuk pelatihan, validasi, dan pengujian memiliki ukuran 256x256 piksel dan ukuran *batch* 32. Untuk setiap varietas benih jagung, data latih terdiri dari 350 citra, data validasi 100 citra dan data uji 50 citra. Data latih dan validasi diambil secara acak (*shuffle*) agar distribusi data merata dan menghindari bias selama pelatihan sedangkan data uji tidak diacak. Model dirancang menggunakan arsitektur Sequential kemudian dikompilasi dengan *optimizer Adaptive Moment Estimation (Adam)* dengan *learning rate default* 0.001. Fungsi loss yang digunakan adalah *categorical cross-entropy*, yang sesuai untuk masalah klasifikasi multi-kelas.

2.4. Pengujian dan evaluasi Model CNN

Setelah pelatihan selesai, model CNN diuji menggunakan dataset uji yang telah disiapkan. Hasil prediksi model CNN kemudian dievaluasi menggunakan *confusion matrix* [12] untuk mengukur kinerja model dalam mengidentifikasi varietas benih jagung. Beberapa metrik evaluasi yang digunakan antara lain akurasi, *precision*, *recall*, dan *F1-score* [12]. Metrik akurasi digunakan untuk mengukur seberapa banyak prediksi model yang benar, dihitung dengan Persamaan (1).

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

Table 2. Detail arsitektur CNN untuk Model_1, Model_2 dan Model_3

Layer (type)	Output shape		
	Model_1	Model_2	Model_3
Input (InputLayer)	(256, 256, 3)	(256, 256, 3)	(256, 256, 3)
conv2d (Conv2D)	(254, 254, 16)	(254, 254, 16)	(254, 254, 32)
max_pooling2d	(127, 127, 16)	(127, 127, 16)	(127, 127, 32)
conv2d_1 (Conv2D)	(125, 125, 32)	(125, 125, 32)	(125, 125, 64)
max_pooling2d_1	(62, 62, 32)	(62, 62, 32)	(62, 62, 64)
conv2d_2 (Conv2D)	-	(60, 60, 64)	(60, 60, 128)
max_pooling2d_2	-	(30, 30, 64)	(30, 30, 128)
flatten (Flatten)	(123008)	(57600)	(115200)
dense (Dense)	(128)	(128)	(128)
dropout (Dropout)	-	-	(128)
dense_1 (Dense)	(5)	(5)	(64)
dropout_1 (Dropout)	-	-	(64)
dense_2 (Dense)	-	-	(5)

Metrik *precision* digunakan untuk mengukur ketepatan model dalam mengidentifikasi benih jagung berkualitas baik, dihitung dengan Persamaan (2).

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

Recall digunakan untuk mengukur seberapa baik model menemukan semua benih jagung, yang dihitung dengan Persamaan (3).

$$Recall = \frac{TP}{TP+FN} \quad (3)$$


Terakhir, *F1-score* untuk mengukur keseimbangan antara *precision* dan *recall*, yang dihitung dengan Persamaan (4).

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (4)$$

dengan TP (*True Positive*) adalah jumlah prediksi benar untuk sampel positif, TN (*True Negative*) adalah jumlah prediksi benar untuk sampel negatif, FP (*False Positive*) adalah jumlah prediksi salah mengidentifikasi sampel negatif sebagai positif, dan FN (*False Negative*) adalah jumlah prediksi salah mengidentifikasi sampel positif sebagai negatif.

3. Hasil dan Pembahasan

Pada Gambar 3 disajikan contoh citra dari 5 varietas benih jagung yang digunakan dalam penelitian ini. Secara visual, dari Gambar 3 terlihat bahwa benih jagung varietas Pertiwi 6 (benih yang direkomendasikan) mirip dengan Pertiwi 2 (benih yang tidak direkomendasikan) dan NK 7328 Sumo (benih yang direkomendasikan) mirip dengan NK 212 (benih yang tidak direkomendasikan). Benih jagung varietas Pioneer P 21 secara visual berbeda dengan keempat varietas yang lain.




Gambar 3. Benih jagung dari 5 varietas

a. Pertiwi 6, b. Pertiwi 2, c. Pioneer P 21, d. NK 7328 Sumo, e. NK 212

3.1. Hasil akuisisi citra benih jagung

Contoh hasil akuisisi citra benih jagung yang akan digunakan sebagai input model CNN disajikan pada Gambar 4. Secara umum dapat dilihat bahwa dalam satu citra, terdapat variasi baik dari segi bentuk, ukuran maupun warna benih jagung dari setiap varietas. Dengan adanya variasi tersebut akan mempermudah model CNN untuk mendapatkan fitur-fitur yang diperlukan sehingga akan meningkatkan akurasi model.




Gambar 4. Sampel benih jagung dari lima varietas yang digunakan sebagai input model CNN

a. Pertiwi 6, b. Pertiwi 2, c. Pioneer P 21, d. NK 7328 Sumo, e. NK 212

3.2. Hasil praproses data

Pada penelitian ini diterapkan beberapa teknik augmentasi citra benih jagung yaitu rotasi, pergeseran horizontal dan vertikal, penyesuaian kecerahan, *zoom* serta *flipping*. Pada Gambar 5 disajikan contoh

hasil proses-proses augmentasi tersebut. Secara umum, augmentasi citra telah menghasilkan citra baru yang berbeda dengan citra asal.

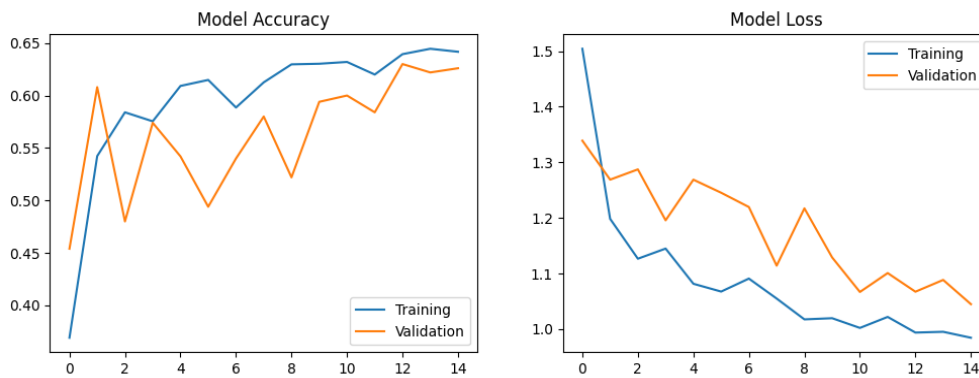


Gambar 5. Contoh hasil augmentasi citra benih jagung

- (a) citra asal
- (b) rotasi 45°
- (c) pergeseran horizontal
- (d) pergeseran vertikal
- (e) penyesuaian kecerahan
- (f) *zooming*
- (g) *flipping*

3.3. Hasil Pelatihan Model CNN

Model_1 dilatih dengan jumlah *epoch* sebanyak 15. Grafik akurasi dan loss Model_1 selama pelatihan dapat dilihat pada Gambar 6. Model_1 menunjukkan performa yang relatif rendah. Akurasi pelatihan dan akurasi validasi berkisar di angka 60%, menunjukkan model *underfitting*. Hal ini mengindikasikan arsitektur model terlalu sederhana untuk menangkap kompleksitas fitur dari *dataset*.



Gambar 6. Sampel akurasi dan loss Model_1 selama pelatihan


Model_2 merupakan perbaikan dari model_1 dengan menambahkan satu layer konvolusi. Grafik akurasi dan loss model_2 selama pelatihan sebanyak 15 *epoch* dapat dilihat pada Gambar 7. Dari Gambar 7 dapat dilihat bahwa model_2 menunjukkan peningkatan performa dibanding Model_1 dengan akurasi pelatihan mencapai 71,72%, namun akurasi validasi yang lebih rendah (58,00%) dengan selisih sekitar 13,72%, yang mengindikasikan adanya *overfitting*. Hal ini berbeda dengan Model_1 yang menunjukkan gejala *underfitting*. Fenomena ini menunjukkan bahwa penambahan kompleksitas model dapat meningkatkan kemampuan model dalam mengenali pola pada data *training*, namun belum optimal dalam generalisasi.



Gambar 7. Sampel akurasi dan loss Model_2 selama pelatihan

Model_3 menggunakan arsitektur yang lebih dalam dengan 3 lapisan konvolusi dan 2 lapisan *fully connected*, serta penambahan *dropout* untuk mengurangi *overfitting*. Grafik akurasi dan *loss* Model_3 selama pelatihan sebanyak 15 *epoch* dapat dilihat pada Gambar 8. Model_3 menunjukkan performa yang lebih baik dengan akurasi pelatihan sebesar 98,03% pada *epoch* ke-15 dan mampu mempertahankan performa tinggi pada *validation* (86,80%). Hal ini menunjukkan kemampuan Model_3 yang lebih baik dalam mengenali pola kompleks pada data dibandingkan Model_2. Penambahan *dropout* terbukti mengurangi *overfitting*, yang ditunjukkan dengan selisih antara akurasi *training* dan validasi yang lebih kecil dibandingkan dengan Model_2.

Namun pada grafik, terlihat bahwa nilai *loss training* dan validasi menunjukkan pola divergensi yang semakin melebar setelah *epoch* ke-7. *Training loss* terus menurun hingga mencapai 0,0881 pada *epoch* ke-15, mengindikasikan model semakin baik mempelajari data pelatihan, sedangkan *validation loss* justru meningkat dari 0,7264 menjadi 1,0932, menandakan gejala *overfitting* mulai terjadi diatas *epoch* ke-7. Meski demikian, *validation accuracy* tetap stabil di sekitar 86%, menunjukkan model masih memiliki kemampuan generalisasi yang cukup baik.



Gambar 8. Sampel akurasi dan loss Model_3 selama pelatihan

3.4. Hasil Pengujian dan Evaluasi Model CNN

Hasil pengujian CNN model_1 menggunakan data uji disajikan pada Tabel 3 dengan akurasi model_1 adalah sebesar 77,60%. Dari Tabel 3 dapat dilihat bahwa kesalahan prediksi yang terjadi adalah antara varietas benih jagung Pertiwi 6 dengan Pertiwi 2 dan NK 7328 Sumo dengan NK 212. Hal ini mengkonfirmasi kemiripan secara visual dari varietas-varietas tersebut seperti yang sudah disebutkan pada bagian sebelumnya. Demikian juga dengan varietas benih jagung Pioneer P 21 yang secara visual berbeda dengan keempat varietas yang lain, hanya ada 2 kesalahan prediksi atau sebesar 4%.

Table 3. Confusion matrix CNN Model_1

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	35	15	0	0	0
Pertiwi 2	8	41	0	1	0
Pioneer 21	0	0	48	2	0
NK 7328 Sumo	0	0	0	46	4
NK 212	0	0	0	26	24

Confusion matrix hasil pengujian model_2 disajikan pada Tabel 4 dengan akurasi pengujian sebesar 83,20%. Model_2 menunjukkan peningkatan signifikan dalam kemampuan mengenali varietas NK 212 dengan 49 dari 50 sampel diklasifikasikan dengan benar. Namun, terjadi penurunan dalam pengenalan NK 7328 Sumo dengan 21 sampel salah diklasifikasi sebagai NK 212. Ini menunjukkan pergeseran bias model dari Model_1 yang cenderung mengklasifikasikan NK 212 sebagai NK 7328 Sumo, menjadi Model_2 yang cenderung mengklasifikasikan NK 7328 Sumo sebagai NK 212. Performa untuk Pioneer P 21 tetap tinggi dengan 49 sampel terklasifikasi dengan benar. Untuk varietas Pertiwi, performa relatif stabil dengan pola kesalahan yang serupa antara Pertiwi 2 dan Pertiwi 6.

Table 4. Confusion matrix CNN Model_2

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	41	9	0	0	0
Pertiwi 2	9	40	0	0	1
Pioneer P 21	1	0	49	0	0
NK 7328 Sumo	0	0	0	29	21
NK 212	0	0	0	1	49

Berdasarkan Tabel 5, performa klasifikasi Model_3 menunjukkan peningkatan signifikan dibandingkan model sebelumnya dengan akurasi pengujian sebesar 89,20%. Peningkatan akurasi tersebut terutama terjadi pada varietas benih jagung NK 7328 Sumo yaitu dari 58% (model_2) menjadi 78% pada model_3. Pola kesalahan model_3 secara umum serupa dengan pola kesalahan pada model_1 dan model_2. Namun demikian, model_3 telah berhasil mengurangi tingkat kesalahan tersebut dibandingkan dengan model-model sebelumnya.

Table 5. Confusion matrix CNN Model_3

Kelas aktual	Kelas prediksi				
	Pertiwi 6	Pertiwi 2	Pioneer P 21	NK 7328 Sumo	NK 212
Pertiwi 6	42	8	0	0	0
Pertiwi 2	5	44	1	0	1
Pioneer P 21	1	0	50	0	0
NK 7328 Sumo	0	0	0	39	11
NK 212	0	0	0	2	48

Perbandingan kinerja ketiga model CNN disajikan pada Tabel 6. Dapat dilihat dari tabel tersebut bahwa kinerja model yang diukur dengan *F1-score* menunjukkan bahwa model_3 merupakan model terbaik dibandingkan kedua model yang lain. Secara umum nilai *F1-score* untuk kelima varietas benih jagung menunjukkan adanya peningkatan dari model_1 ke model_2 hingga ke model_3. Terdapat pengecualian untuk varietas benih jagung P21 dimana nilai *F1-score* untuk ketiga model menunjukkan nilai yang hampir sama yaitu di sekitar nilai 99%. Hal ini mengkonfirmasi bahwa varietas benih jagung P21 secara visual berbeda dengan keempat varietas yang lain.

Table 6. Evaluation matrix CNN model_1, model_2 dan model_3

Varietas	Model_1			Model_2			Model_3		
	P	R	F1	P	R	F1	P	R	F1
Pertiwi 6	0.81	0.70	0.75	0.80	0.82	0.81	0.89	0.84	0.87
Pertiwi 2	0.73	0.82	0.77	0.82	0.80	0.81	0.85	0.88	0.86
P21	1.00	0.96	0.98	1.00	0.98	0.99	0.98	1.00	0.99
NK-7328	0.61	0.92	0.74	0.97	0.58	0.72	0.95	0.78	0.86
NK-212	0.86	0.48	0.62	0.69	0.98	0.81	0.81	0.96	0.88

Keterangan: P = *precision*, R = *recall*, F1 = *F1-score*

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model CNN dengan tiga lapisan konvolusi dan 2 lapisan *fully connected* dengan *dropout* mencatat performa terbaik, mencapai akurasi 89,20% pada data *testing*. Model CNN tersebut telah berhasil mengklasifikasikan varietas benih jagung yang secara visual memiliki kemiripan. Untuk pengembangan penelitian selanjutnya, disarankan untuk menambah epoch selama pelatihan dan menerapkan *hyperparameter tuning* agar diperoleh model CNN dengan kinerja yang lebih baik.

Daftar Pustaka

- [1] B. Irawan, "Fenomena Anomali Iklim El Nino dan La Nina: Kecenderungan Jangka Panjang dan Pengaruhnya Terhadap Produksi Pangan," *Forum Penelitian Agro Ekonomi*, vol. 24, no. 1, pp. 28–45, Jul. 2006.
- [2] Kementan, "Laporan Kinerja Kementerian Pertanian 2023," 2023. [Online]. Available: www.pertanian.go.id
- [3] A. Sitorus, N. R. E. Kotta, and E. Y. Hosang, "Keragaan Pertumbuhan dan Produksi Jagung Hibrida pada Agroekosistem Lahan Kering Iklim Kering Nusa Tenggara Timur," in *Seminar Nasional Lahan Suboptimal ke-8 Tahun 2020*, Palembang: Penerbit & Percetakan Universitas Sriwijaya, Oct. 2020, pp. 62–72.
- [4] A. Syahbani and E. Suastuti, "Disparitas Penjatuhan Pidana Terhadap Pelaku Usaha Yang Memperdagangkan Benih Jagung Bantuan Pemerintah," *Journal Inicio Legis*, vol. 4, no. 1, Jun. 2023.
- [5] A. Muhajir, "Sindiket pemalsu merek benih jagung dibongkar, korban rugi Rp 5 miliar," *detik.com*. Accessed: Mar. 25, 2025. [Online]. Available: <https://news.detik.com/berita-jawa-timur/d-5293569/sindiket-pe-malsu-merek-benih-jagung-dibongkar-korban-rugi-rp-5-miliar>
- [6] M. A. Nugroho and M. M. Sebatubun, "Klasifikasi Varietas Kopi Berdasarkan Green Bean Coffee Menggunakan Metode Machine Learning," vol. 1, no. 2, pp. 2715–3088, 2020.

- [7] R. Ardianto and S. kartika Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *Jurnal Kolaboratif Sains*, vol. 6, no. 12, pp. 2081–2092, Dec. 2023, doi: 10.56338/jks.v6i12.4938.
- [8] V. Chandra, J. H. Jaman, and Garno, "Identifikasi Varietas Jagung Mutiara Berdasarkan Data Citra Digital Menggunakan Algoritma K-Nearest Neighbor," vol. 16, 2022, [Online]. Available: <https://journal.uniku.ac.id/index.php/ilkom>
- [9] H. Lee and J. Song, "Introduction to convolutional neural network using Keras; An understanding from a statistician," *Commun Stat Appl Methods*, vol. 26, no. 6, pp. 591–610, 2019, doi: 10.29220/CSAM.2019.26.6.591.
- [10] J. Wu, "Introduction to Convolutional Neural Networks," 2017. Accessed: May 13, 2025. [Online]. Available: <https://cs.nju.edu.cn/wujx/paper/CNN.pdf>.
- [11] V. L. H. Josephine, A. P. Nirmala, and V. L. Alluri, "Impact of Hidden Dense Layers in Convolutional Neural Network to enhance Performance of Classification Model," *IOP Conf Ser Mater Sci Eng*, vol. 1131, no. 1, p. 012007, Apr. 2021, doi: 10.1088/1757-899x/1131/1/012007.
- [12] J. D. Novakovic, A. Veljovic, S. S. Ilic, Z. Papic, and M. Tomovic, "Evaluation of Classification Models in Machine Learning," *Theory and Applications of Mathematics & Computer Science*, vol. 7, no. 1, pp. 39–46, 2017.