

## ***Classification of Ceramic Roof Tiles Using the CNN method*** **[Klasifikasi Genteng Keramik Menggunakan Metode CNN]**

Achmad Danu Zakaria<sup>1)</sup>, Ade Eviyanti<sup>\*2)</sup>, Metatia Intan Mauliana<sup>3)</sup>, Azmuri Wahyu Azinar<sup>4)</sup>

<sup>1)</sup> Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>2)</sup> Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>3)</sup> Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>4)</sup> Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

\*Email Penulis Korespondensi: adeeviyanti@umsida.ac.id

**Abstract.** *The research on tile classification using Convolutional Neural Network (CNN) aims to improve and address issues in the sorting process within the tile manufacturing industry. The accuracy level in manual sorting processes is very low due to errors caused by visual limitations and physical fatigue. By leveraging the capabilities of Convolutional Neural Network (CNN), a model was developed to classify tiles. This research involved several processes, including literature review, dataset collection, dataset splitting, preprocessing, Convolutional Neural Network (CNN) design, training, testing, and result evaluation. The study used 69 tile images divided into three classes: KW 1, KW 2, and KW 3. The results of testing the Convolutional Neural Network (CNN) on tile classification using 100 epochs with a data split of 90% training and 10% validation yielded an accuracy rate of 100%.*

**Keywords** – *Classification, Deep Learning, Ceramic Roof tile, Image Processing*

**Abstrak.** Penelitian klasifikasi genteng menggunakan *Convolutional Neural Network (CNN)* bertujuan untuk meningkatkan dan mengatasi masalah pada proses sortir dalam industri pembuatan genteng. Tingkat akurasi yang dilakukan pada proses persortiran manual sangat rendah karena rentan terhadap kesalahan akibat keterbatasan visual dan kelelahan fisik. Dengan pemanfaatan kemampuan *Convolutional Neural Network (CNN)*, dikembangkan sebuah model untuk mengklasifikasikan genteng. Penelitian ini melewati beberapa proses, yaitu studi literatur, pengambilan dataset, pembagian dataset, *preprocessing*, perancangan *Convolution neural Network (CNN)*, *training*, *testing*, dan evaluasi hasil. Penelitian ini menggunakan 69 citra genteng dibagi dalam tiga kelas KW 1, KW 2, dan KW 3. Hasil dari pengujian *Convolutional Neural Network (CNN)* pada klasifikasi genteng menggunakan 100 epoch dengan perbandingan data latih 90% dan validasi 10% menghasilkan tingkat akurasi sebesar 100%.

**Kata Kunci** - *Klasifikasi, Deep Learning CNN, Genteng Keramik, Pengolahan Citra*

### **I. PENDAHULUAN**

Industri konstruksi dan bangunan memainkan peran penting dalam pembangunan infrastruktur, salah satunya adalah genteng. Genteng adalah salah satu jenis penutup atap yang umum digunakan, berfungsi sebagai pelindung dari sinar matahari dan air hujan, serta memiliki kemampuan untuk meningkatkan aspek estetika rumah dengan menambah keindahan pada penampilannya [1]. Terdapat berbagai jenis genteng, seperti genteng keramik, genteng beton, genteng metal, genteng aspal, genteng kayu, dan genteng slate. Setiap jenis genteng memiliki keunikan dan karakteristiknya sendiri, termasuk ketahanan terhadap cuaca, aspek finansial, daya tahan, dan estetika [2].

Berdasarkan data yang diperoleh dari badan pusat statistik kabupaten Malang, genteng keramik, genteng metal, dan genteng tanah liat merupakan jenis atap yang paling dominan digunakan oleh bangunan, dengan presentase mencapai 92.48% pada tahun 2020. Preferensi terhadap jenis ini disebabkan oleh kekuatan struktural, ketahanan terhadap berbagai kondisi cuaca, serta nilai estetika yang lebih tinggi dibandingkan dengan jenis genteng yang lain. Selain itu, penggunaan genteng ini juga didorong oleh ketersediaan bahan baku yang melimpah dan teknologi produksi yang baik, sehingga menghasilkan produk yang lebih efisien dan ekonomis.

Dalam proses produksi genteng, tahap sortir merupakan salah satu proses akhir yang krusial untuk menentukan tingkatan kualitas produk. Kualitas genteng dinilai berdasarkan beberapa parameter, antara lain warna, keutuhan bentuk, dan tekstur. Saat ini, proses sortir genteng keramik masih dilakukan secara manual, dengan tingkat akurasi yang dihasilkan sangat rendah dan tidak konsisten, disebabkan oleh keterbatasan visual, kelelahan fisik, dan persepsi subjektif masing-masing individu. Oleh karena itu, diperlukan pendekatan yang lebih dengan teknologi untuk meningkatkan akurasi dan konsistensi. Penerapan otomasi dalam dunia industri bertujuan untuk mengatasi potensi kesalahan manusia. Hal ini dilatarbelakangi oleh keterbatasan alamiah manusia, yang cenderung mengalami kelelahan dan kurang presisi ketika terlibat dalam pekerjaan yang memerlukan konsistensi dalam jangka waktu yang lama [3].

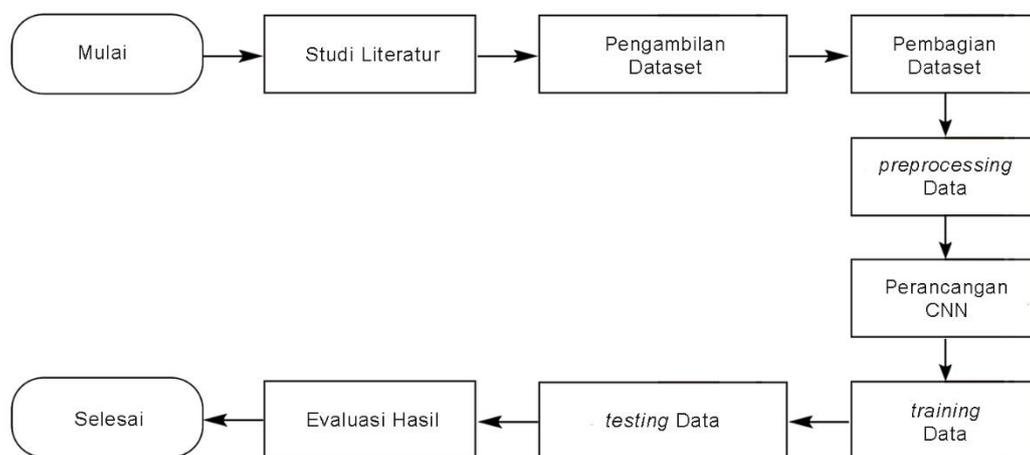
Teknologi berkembang sangat cepat dan bisa diakses dengan mudah dan kapan saja [4]. Salah satu perkembangan teknologi saat ini yaitu pengolahan citra dilakukan melalui penggunaan *deep learning* [5]. Dalam *deep learning*, *Convolution neural Network (CNN)* menjadi metode pilihan yang sering digunakan dalam penelitian [8]. Keakuratan akurasi telah menjadikannya sebagai teknik yang paling sering diterapkan di antara berbagai metode lain dalam dunia pengolahan citra [9]. *Deep learning* digunakan dalam pengolahan citra untuk meningkatkan efisiensi pengenalan objek dengan kecepatan dan akurasi tinggi, serta mampu mengolah data dengan skala besar secara efektif [6]. Pengolahan citra menjadi suatu bentuk teknologi yang tidak hanya menyelesaikan tantangan dalam manipulasi gambar, tetapi juga membuka pintu untuk penggunaan citra dalam penelitian yang lebih lanjut [7]. Dengan keunggulan teknologi ini, penelitian mengenai klasifikasi genteng muncul sebagai pengembangan terbaru memanfaatkan CNN.

Beberapa penelitian sebelumnya telah menggunakan *Convolution neural Network (CNN)* untuk klasifikasi objek. Salah-satunya penelitian untuk klasifikasi citra wayang yang hasil penelitian nilai akurasi, *loss*, presisi, dan *recall* mencapai masing-masing sebesar 97%, 2%, 93%, dan 87% [10]. Penelitian lainnya klasifikasi citra jenis-jenis beras menghasilkan nilai rata-rata *recall*, *presisi*, dan *F1-score* untuk setiap jenisnya yaitu beras C4 96,3%, beras ketan 100%, beras merah 100%, dan beras naga 96% [11]. Penelitian selanjutnya klasifikasi citra telur untuk menentukan kualitas diperoleh hasil ketepatan sebesar 80%, dari 6 data uji coba hanya 1 data yang tidak sesuai dengan hasil [12]. Penelitian berikutnya klasifikasi citra kebakaran dan non kebakaran, dengan menggunakan 950 citra menghasilkan model dengan tingkat akurasi 98.8% dan *loss* 2.6% [13].

Beberapa penelitian yang menggunakan *Convolution neural Network (CNN)* untuk klasifikasi diatas menghasilkan presentase hasil akhir yang cukup baik, dan dapat disimpulkan bahwa metode ini menunjukkan kinerja yang baik pada klasifikasi citra. Berdasarkan temuan tersebut, diharapkan pada penelitian klasifikasi genteng menggunakan CNN menghasilkan model dengan nilai akhir yg baik.

## II. METODE

Pada penelitian ini disusun dan dirancang dengan langkah yang terstruktur dan sistematis, memastikan penelitian ini menghasilkan data yang valid sesuai dengan tujuan penelitian yang diinginkan. Software program yang digunakan adalah google colab sedangkan untuk penyimpanan dataset menggunakan google drive [14]. Selain itu, penelitian ini ditunjang dengan perangkat keras dan perangkat lunak dengan spesifikasi seperti dalam tabel 1 dan tabel 2.



**Gambar 1.** Alur Penelitian

Gambar 1 menunjukkan langkah-langkah mencakup studi literatur, pengambilan dataset, pembagian dataset, *preprocessing*, perancangan *Convolution neural Network (CNN)*, *training*, *testing*, dan evaluasi hasil.

Tabel 1. Perangkat Keras

No	Aspek	Spesifikasi
1	<i>Processor</i>	Intel(R) Core(TM) i3-5010U CPU @ 2.10GHz 2.10 GHz
2	<i>Memory</i>	4 GB RAM
3	<i>Storage</i>	HDD 512 GB
4	<i>Operating System</i>	Windows 10 Pro

Tabel 2. Perangkat Lunak

No	Aspek	Perangkat Lunak
1	Bahasa Pemrograman	Phyton
2	<i>Software Programe</i>	<i>Google Colaboratory</i>

### A. Studi Literatur

Tahap awal ini dilakukan dengan mencari informasi dari beberapa sumber seperti buku dan jurnal sesuai dengan permasalahan yang diangkat [10]. Tahap ini dilakukan untuk memudahkan peneliti dalam mengembangkan dan menemukan referensi baru. Studi literatur ini mencakup penelitian teori dasar, metode penelitian yang telah digunakan sebelumnya, dan temuan-temuan terbaru di bidang pengolahan citra serta penerapan *Convolution neural Network (CNN)* dalam klasifikasi objek.

### B. Pengambilan Dataset

Dalam proses pengumpulan dataset, dilakukan pengambilan citra genteng langsung menggunakan kamera dengan format jpg. Dengan pengambilan data dari sumber yang tepat, memastikan representasi yang cukup dari setiap jenis genteng dalam dataset yang digunakan untuk keperluan model *training* dan *testing* model klasifikasi.

Tabel 3. Dataset Citra Genteng Keramik

No	Jenis	Data	Klasifikasi	Gambar
1	KW 1	23 Gambar	Warna cerah dan tanpa retak	
2	KW 2	23 Gambar	Warna pudar dan tanpa retak	
3	KW 3	23 Gambar	Warna pudar dan retak	

Tabel 3 diatas merupakan pengelompokan kelas dataset yang dibagi menjadi tiga kelas, masing-masing kelas Mempunyai label dan representasi. KW 1 representasinya warna cerah dan tanpa retak, KW 2 warna pudar dan tanpa retak, sedangkan KW 3 warna pudar dan dengan retak. Untuk masing-masing kelas diambil sample data sebanyak 23 citra.

### C. Pembagian Dataset

Setelah mengumpulkan dataset gambar genteng, dataset tersebut dibagi menjadi 2 dataset, yaitu dataset *training* dan *testing*. Dataset *training* digunakan untuk melatih model *Convolution neural Network (CNN)* agar dapat mengenali pola pada gambar genteng. Dataset *testing* digunakan untuk menguji kinerja akhir model secara objektif, memberikan ukuran akurasi dan konsistensi dalam mengklasifikasikan genteng keramik dalam situasi dunia nyata. Pembagian dataset ini membantu mencegah *overfitting* dan memastikan bahwa model dapat menghasilkan prediksi yang baik pada data yang tidak digunakan selama *training*.

Tabel 4. Pembagian Dataset

Dataset	
<i>Training</i>	<i>Testing</i>
60	9

Tabel 4 menjelaskan pembagian 69 dataset, 60 data *training* dan 9 data *testing*, dataset yang sudah dibagi akan dikelompokkan menjadi tiga folder yaitu folder KW 1, folder KW 2, dan folder KW 3. Tahap ini bertujuan untuk memudahkan pelabelan saat *training* dan *testing* dilakukan.

#### D. Preprocessing Data

Sebelum data citra genteng keramik diolah terlebih dahulu dilakukan pra-pemrosesan, tahap ini sangat penting karena citra gambar yang telah dikumpulkan memiliki variasi ukuran piksel yang tidak seragam. Tahap pra-pemrosesan bertujuan untuk menyelesaikan berbagai permasalahan yang bisa mengganggu hasil dari proses data [4]. Beberapa langkah untuk melakukan pra-pemrosesan, yaitu

- *Data Augmented*  
Augmentasi data digunakan untuk memperluas ukuran dataset *training* secara artifisial dengan membuat versi modifikasi dari gambar-gambar dalam dataset. Teknik ini mencegah *overfitting* dan meningkatkan kemampuan generalisasi model.
- *Data Generation*  
Metode '*flow-from\_directory*' digunakan untuk menghasilkan batch data gambar dengan augmentasi *real-time*, memastikan efisiensi penggunaan memori
- *Image Preprocessing for prediction*.  
Untuk melakukan prediksi, gambar input di *preprocessing* dengan mengubahnya menjadi array, dan menormalkan nilai piksel. langkah pra pemrosesan data yang diimplementasikan adalah menormalkan ukuran piksel pada citra asli sehingga setiap citra memiliki dimensi piksel yang serupa [13].

#### E. Perancangan Convolution neural Network (CNN)

Pilihan metode *Convolution neural Network (CNN)* didorong oleh sifat dataset yang terdiri dari data citra dan juga karena jumlah dataset yang signifikan. Keputusan ini diambil dengan mempertimbangkan kebutuhan akan pendekatan yang tidak hanya menawarkan kinerja klasifikasi yang cepat, tetapi juga menjamin tingkat akurasi yang optimal. Struktur *Convolution neural Network (CNN)* mempunyai beberapa tahapan yaitu *convolution layer*, *pooling layer*, dan *fully connected layer* [15].

##### a. Feature Learning

- *Convolution Layer*  
Proses konvolusi dilakukan untuk tujuan ekstraksi pada citra input [16]. Proses konvolusi melibatkan pergeseran kernel secara horizontal dan vertikal dengan ukuran pergeseran yang disebut sebagai parameter *stride*. Fungsi aktivasi *ReLU* diterapkan untuk mengubah nilai negatif menjadi 0.
- *Pooling Layer*  
*Pooling layer* adalah proses yang digunakan untuk mereduksi ukuran data citra dengan tujuan meningkatkan invariasi warna [16]. Salah satu operasi yang umum digunakan adalah *max pooling*, yang membagi output dari lapisan konvolusi menjadi beberapa grid kecil dan mengambil nilai maksimal dari dari setiap grid untuk menyusun metrik citra yang direduksi. singkatnya *Proses max pooling* difokuskan pada dimensi gambar untuk meningkatkan efisiensi perhitungan dan menghindari kemungkinan *overfitting*.

##### b. Tahap Klasifikasi

###### *Flatten Layer*

Operasi *flatten* dilakukan untuk mereshape *feature map* menjadi vektor, sehingga dapat dijadikan input untuk *Fully Connected Layer*. *Fully Connected Layer* merupakan *perceptron* multilayer dengan jumlah neuron yang telah ditentukan di hidden layer. Metode *dropout* diterapkan untuk menonaktifkan sebagian koneksi ke setiap neuron, menghindari *overfitting*.

#### F. Training Data

*Training proses* adalah tahap dimana *Convolution neural Network (CNN)* dilatih untuk mencapai akurasi yang lebih tinggi dalam klasifikasi [4]. Tahap *training* data pada jaringan saraf *Convolution neural Network (CNN)* dilakukan menggunakan dataset gambar yang dikelompokkan ke dalam tiga kelas. Untuk meningkatkan variasi dan mencegah *overfitting*, dataset di augmentasi secara *real-time* menggunakan *ImageDataGenerator*. Augmentasi yang diterapkan mencakup *rescaling*, *shear*, *zoom*, dan *flipping horizontal*.

Model *Convolution neural Network (CNN)* yang dikembangkan memiliki beberapa lapisan konvolusi dengan fungsi aktivasi *ReLU*, dilanjutkan dengan lapisan *pooling* untuk mengurangi dimensi fitur. Setelah lapisan konvolusi, data diproses melalui lapisan *fully connected* dengan aktivasi *softmax* untuk mengeluarkan probabilitas klasifikasi. Proses *training* berlangsung dengan menggunakan pembagian data latih 90 %, data uji 10% dan data latih 80%, data uji 20% dengan *epoch* 10, 50, dan 100 dan ukuran *batch* 32, menggunakan fungsi *loss categorical cross-entropy* dan *optimizer adam*.

### G. Testing Data

Setelah tahap *training*, model *Convolution neural Network (CNN)* melewati proses *testing* menggunakan dataset yang terpisah, yang tidak pernah digunakan dalam proses *training*. Dataset *testing* ini juga telah melewati proses normalisasi untuk memastikan konsistensi data dalam pengolahan data. tahap *testing* ini bertujuan untuk memberikan gambaran objektif terhadap kemampuan model dalam mengklasifikasikan jenis genteng pada data yang benar-benar baru dan belum pernah dilihat dalam model sebelumnya.

Proses *testing* dilakukan dengan menghitung prediksi model terhadap gambar-gambar dalam dataset *testing*. Setiap gambar diproses melalui model untuk mendapatkan prediksi kelasnya. Hasil prediksi ini kemudian dibandingkan dengan label sebenarnya untuk menghitung akurasi.

### H. Evaluasi Hasil

Kinerja model dievaluasi berdasarkan beberapa metrik termasuk akurasi, presisi, *recall*, dan *F1-score*, yang dihitung untuk memberikan gambaran lebih rinci mengenai performa klasifikasi model untuk setiap kelas.

## III. HASIL DAN PEMBAHASAN

### A. Hasil Training

Tahap *training* dataset menggunakan *google colab* dengan percobaan 6 skenario dan disetiap percobaan dilakukan *restart session* untuk hasil yang akurat. Proses ini menghasilkan model file *training* baru yang disimpan pada *google drive* dengan nama *genteng\_clasification\_scenario.h5*. pada tabel 5 merupakan hasil dari *testing* dengan iterasi yang berbeda-beda.

Tabel 5. Hasil Training

Data Latih	Data Validasi	Epoch	Loss	Akurasi
90%	10%	10	0.7231	66.66%
		50	0.3970	83.33%
		100	0.3591	83.33%
80%	20%	10	0.6074	66.66%
		50	0.4978	83.33%
		100	0.4927	83.33%

Dari tabel 5 yang disajikan, disimpulkan bahwa dengan menggunakan kombinasi dan pemisahan yang tepat menghasilkan tingkat akurasi tinggi dan kerugian rendah pada skenario dengan 100 *epoch* dan pembagian data uji 90% dan validasi 10%, mencapai akurasi tertinggi sebesar 83.33% pada epoch ke-85 dan Loss terendah 0.3591 pada epoch ke-29. Fenomena ini menunjukkan bahwa hubungan antara loss dan akurasi selama pelatihan model tidak selalu linier. Epoch ke-29, meskipun mengalami penurunan loss yang signifikan, tidak menunjukkan akurasi yang optimal. Ini menunjukkan bahwa model mengalami *overfitting*, di mana model terlalu menyesuaikan diri dengan data pelatihan dan kurang mampu menggeneralisasi data validasi dengan baik. Di sisi lain, epoch ke-85 mungkin menunjukkan titik di mana model berhasil menyeimbangkan kemampuannya dalam mengenali pola pada data validasi, meskipun loss pada epoch tersebut tidak berada pada titik terendah.

Perbedaan ini menggaris bawahi bahwa metrik evaluasi seperti loss dan akurasi tidak selalu sejalan selama pelatihan. Meskipun epoch ke-29 menunjukkan nilai loss yang rendah, akurasi model meningkat pada epoch ke-

85, yang mungkin menunjukkan bahwa model berhasil memberikan prediksi yang lebih tepat pada data validasi. Oleh karena itu, meskipun nilai loss dapat dikurangi pada epoch tertentu, akurasi model mungkin mencapai titik tertinggi pada epoch yang berbeda, mencerminkan kemampuan model dalam generalisasi yang lebih baik.

Temuan ini mengingatkan kita pada pentingnya memantau berbagai metrik evaluasi untuk mendapatkan gambaran yang lebih komprehensif tentang performa model, serta perlunya pendekatan evaluasi yang lebih mendalam untuk menilai efektivitas model secara keseluruhan.

## B. Hasil Testing

Berdasarkan hasil dari *training*, dalam proses *testing* memutuskan menggunakan iterasi data latih dan data validasi dengan *epoch* 100 dengan perbandingan 90% dan 10%.

**Tabel 6.** Hasil *Testing*

No	Label Gambar	Kelas	Output	Status
1	Uji1	KW3	KW3	Sukses
2	Uji2	KW2	KW2	Sukses
3	Uji3	KW1	KW1	Sukses
4	Uji4	KW3	KW3	Sukses
5	Uji5	KW2	KW2	Sukses
6	Uji6	KW1	KW1	Sukses
7	Uji7	KW1	KW1	Sukses
8	Uji8	KW3	KW3	Sukses
9	Uji9	KW2	KW2	Sukses

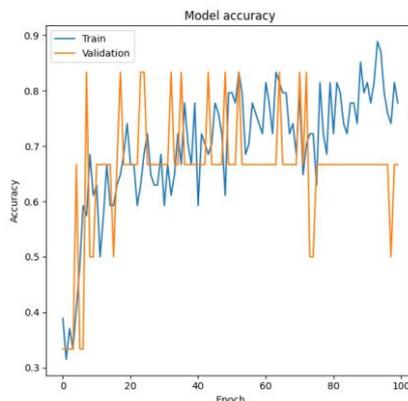
Berdasarkan Tabel 6 hasil *testing* citra genteng baru mendapatkan hasil dari 9 citra sukses 0 citra yang gagal, untuk perhitungan akurasi dihitung pada tahap evaluasi. Hasil tangkapan layar klasifikasi genteng pada data *testing* dapat dilihat pada gambar 2.



**Gambar 2.** Hasil klasifikasi data uji

Dari gambar 2 menunjukkan bahwa representasi kelas pada genteng sesuai dengan hasil klasifikasi masing-masing.

### C. Hasil Evaluasi

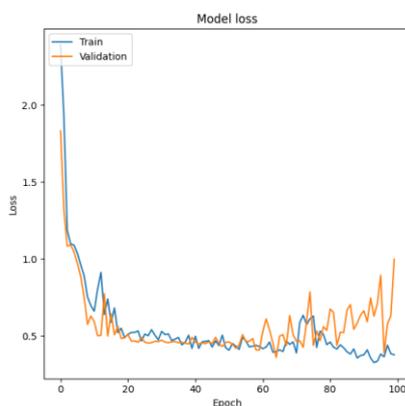


**Gambar 3.** Grafik akurasi pada *training*

Pada gambar 3 menampilkan grafik akurasi dari *training*, menunjukan peningkatan akurasi sampai *epoch* ketujuh, menunjukkan peningkatan tajam baik pada data pelatihan maupun validasi hingga mencapai puncak sekitar *epoch* ketujuh. Peningkatan tajam ini mengindikasikan bahwa model berhasil belajar pola dasar dalam data dengan baik pada tahap awal pelatihan, serta mampu mengaplikasikan pola tersebut pada data validasi dengan efektif. Terjadi penurunan akurasi pada *epoch* kesembilan di kedua set, diikuti dengan fluktuasi signifikan, penurunan ini dapat disebabkan oleh beberapa faktor, termasuk learning rate yang terlalu tinggi, noise dalam data, atau overfitting sementara. Model mungkin melompati minima lokal atau menyesuaikan diri terlalu spesifik dengan data pelatihan pada tahap ini.

Akurasi kembali meningkat setelah fluktuasi awal, mencapai puncak lagi sekitar *epoch* keenam belas, peningkatan akurasi ini menunjukkan bahwa model mungkin telah menyesuaikan hyperparameter atau menemukan pola baru dalam data, meskipun model belum sepenuhnya stabil dalam pembelajarannya. Akurasi pada data pelatihan mulai stabil sampai sekitar *epoch* ketujuhpuluh, sementara akurasi pada data validasi menunjukkan tren penurunan. Stabilitas akurasi pelatihan menunjukkan bahwa model telah mencapai konvergensi pada data pelatihan, tetapi penurunan akurasi pada data validasi menunjukkan adanya overfitting, di mana model terlalu spesifik pada data pelatihan.

Akurasi data validasi terus menurun hingga *epoch* terakhir, penurunan akurasi ini adalah indikasi overfitting yang lebih jelas, di mana model tidak dapat menggeneralisasi dengan baik pada data validasi yang tidak terlihat sebelumnya.

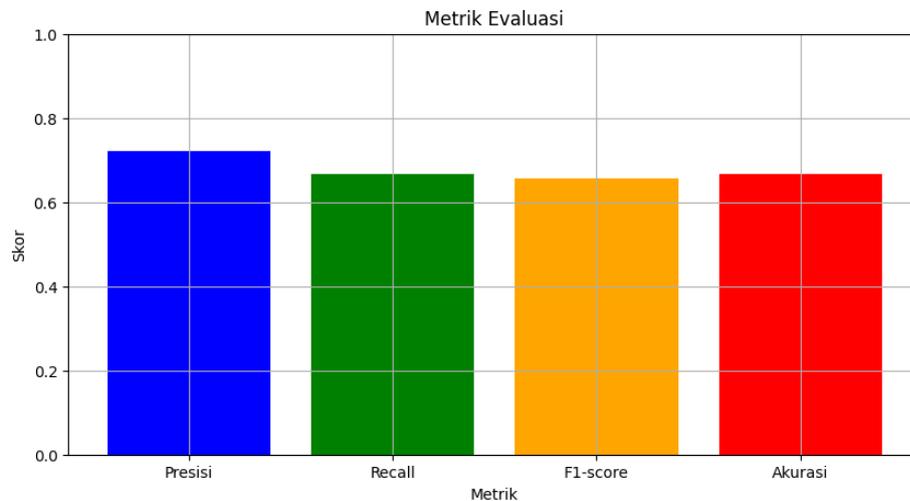


**Gambar 4.** Grafik loss pada *training*

Setelah itu, pada gambar 4 grafik loss nilai loss mengalami penurunan cepat pada kedua set (training dan validation) selama *epoch* awal. Penurunan yang tajam ini menunjukkan bahwa model dengan cepat belajar dari data, mengindikasikan bahwa model mampu mengidentifikasi pola dasar dalam data pada tahap awal pelatihan. Nilai loss pada kedua set mulai stabil sekitar *epoch* ke-20, meskipun ada fluktuasi kecil. Stabilisasi loss ini menunjukkan bahwa model mendekati konvergensi. Fluktuasi kecil mungkin mencerminkan variasi normal dalam proses pembelajaran atau dampak dari hiperparameter yang digunakan.

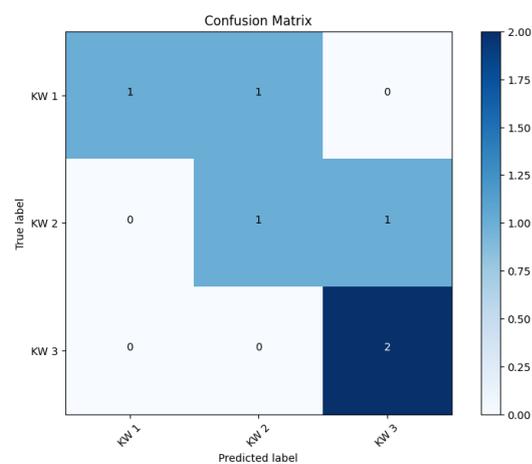
Peningkatan nilai loss pada validation set terjadi setelah *epoch* ke-70, peningkatan loss pada data validasi ini menunjukkan kemungkinan overfitting, di mana model telah menyesuaikan diri secara berlebihan dengan data

pelatihan dan tidak dapat menggeneralisasi dengan baik pada data validasi. Fluktuasi loss yang meningkat mengindikasikan ketidakstabilan dalam performa model pada data yang tidak terlihat sebelumnya.



**Gambar 5.** Diagram evaluasi metrik

Pada gambar 5, diagram hasil evaluasi model menunjukkan akurasi 66,67%, yang mengindikasikan proporsi prediksi yang benar dari keseluruhan data. Presisi model adalah 72,22%, menandakan bahwa sebagian besar dari prediksi positif adalah benar. Recall model mencapai 66,67%, menunjukkan bahwa model mampu mengidentifikasi dua pertiga dari kasus positif. F1 Score sebesar 65,56% mencerminkan keseimbangan yang cukup baik antara presisi dan recall, meskipun ada ruang untuk perbaikan.



**Gambar 6.** Confusion Matrix

Pada gambar 6 *Confusion matrix* untuk kelas Kw 1, model memiliki presisi sebesar 100%. Ini berarti setiap kali model memprediksi Kw 1, prediksinya adalah benar. Namun, recall untuk Kw 1 hanya mencapai 50%, yang menunjukkan bahwa model hanya mampu mendeteksi 50% dari semua data yang seharusnya diklasifikasikan sebagai Kw 1. Dengan kombinasi ini, skor F1 untuk Kw 1 adalah 0.67, yang menunjukkan adanya ketidakseimbangan antara presisi dan recall.

Untuk Kw 2, presisi model adalah 50%, yang menunjukkan bahwa hanya setengah dari prediksi Kw 2 yang benar. Recall juga berada di angka 50%, yang artinya model hanya dapat mendeteksi 50% dari data yang benar-benar Kw 2. Skor F1 untuk Kw 2 adalah 0.5, mencerminkan ketidakseimbangan dalam presisi dan recall yang kurang optimal.

Sebaliknya, untuk Kw 3, model menunjukkan kinerja yang sangat baik. Presisi Kw 3 adalah 100%, berarti setiap prediksi Kw 3 adalah benar. Selain itu, recall Kw 3 juga mencapai 100%, menunjukkan bahwa model berhasil mendeteksi semua data yang termasuk dalam kategori Kw 3. Skor F1 untuk Kw 3 adalah 1, yang menunjukkan bahwa model sangat efektif dalam mengidentifikasi Kw 3 dengan presisi dan recall yang optimal.

Secara keseluruhan, model ini berhasil dengan sangat baik dalam mengidentifikasi Kw 3, namun performanya kurang memadai untuk Kw 1 dan Kw 2, terutama dalam hal recall. Pada hasil *testing* didapat sukses 9 dan gagal 0, untuk evaluasi pada hasil *testing* menggunakan perhitungan persamaan.

$$Akurasi = \frac{9}{9} \times 100\% = 100\%$$

Dari hasil perhitungan diatas, dapat disimpulkan pada *testing* data untuk tingkat akurasi dengan menggunakan data uji sebanyak sembilan dari 3 kelas mencapai 100%.

## IV. KESIMPULAN

### A. Kesimpulan

Model menunjukkan performa yang sangat baik dalam pengujian dengan akurasi sempurna sebesar 100% pada data uji, namun terdapat indikasi overfitting selama pelatihan, yang mempengaruhi keseimbangan antara akurasi dan loss. Kinerja model menunjukkan variasi signifikan antar kelas, dengan hasil yang sangat baik pada Kw 3, tetapi kurang memadai untuk Kw 1 dan Kw 2, terutama dalam hal recall.

### B. Saran

Untuk meningkatkan performa model secara keseluruhan, disarankan untuk melakukan eksperimen tambahan dengan variasi parameter dan epoch serta menerapkan teknik regularisasi seperti dropout untuk mengurangi overfitting. Selain itu, peningkatan kualitas dan kuantitas data pelatihan serta eksplorasi teknik augmentasi data dapat membantu model dalam mengenali pola dengan lebih baik dan meningkatkan kemampuan deteksi pada semua kelas.

## REFERENSI

- [1] A. Khairunisa and Aviasti, "Usulan Perbaikan Proses Pembuatan Genteng dengan Menggunakan Metode Taguchi pada Home Industri Mahkota," *Bandung Conf. Ser. Ind. Eng. Sci.*, vol. 3, no. 1, Jan. 2023, doi: 10.29313/bcsies.v3i1.6614.
- [2] D. Prasetyo and A. Nugroho, "ISSN 2338-5677 Cetak ISSN 2548-6646 Online Sistem Pendukung Keputusan Pemilihan Genteng Menggunakan Metode Analytical Hierarchy Process ISSN 2338-5677 Cetak ISSN 2548-6646 Online," vol. 11, no. 1, pp. 24–30, 2023.
- [3] M. Irfi, F. I. Adhim, and F. Istiqomah, "Implementasi Metode Pid untuk Mengontrol Posisi Motor Servo pada Sistem Sortir Berat Adonan," vol. 10, no. 2, 2021.
- [4] F. N. Cahya, N. Hardi, D. Riana, and S. Hadiani, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network ( CNN )," vol. 10, pp. 618–626, 2021.
- [5] Y. Pratama, E. Rasywir, D. Kisbianty, and B. Irawan, "Eksperimen Layer Pooling menggunakan Standar Deviasi untuk Klasifikasi Dataset Citra Wajah dengan Metode CNN," vol. 5, no. 1, pp. 200–210, 2023, doi: 10.47065/bits.v5i1.3604.
- [6] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," vol. 01, pp. 104–108, 2019.
- [7] A. Salsabila, R. Yunita, and C. Rozikin, "Identifikasi Citra Jenis Bunga menggunakan Algoritma KNN dengan Ekstraksi Warna HSV dan Tekstur GLCM," *Technomedia J.*, vol. 6, no. 1, pp. 124–137, 2021, doi: 10.33050/tmj.v6i1.1667.
- [8] A. B. Prakosa, F. T. Informasi, U. Kristen, and S. Wacana, "IMPLEMENTASI MODEL DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK ( CNN ) PADA CITRA PENYAKIT DAUN JAGUNG," no. April, pp. 107–116, 2023.
- [9] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation," vol. 4, no. 1, pp. 45–51, 2020.
- [10] M. Resa, A. Yudianto, and H. Al Fatta, "WAYANG DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK," no. 2, pp. 182–190, 2020.
- [11] I. S. Ardiansyah, "Implementasi Convolutional Neural Network Untuk Klasifikasi Jenis Beras Berdasarkan Citra Digital," vol. 12, no. 1, pp. 4172–4182, 2023.
- [12] C. Rahmad, E. Rohadi, and E. A. Widyatama, "APLIKASI PENENTUAN TINGKAT KUALITAS TELUR AYAM BERDASARKAN WARNA DAN TEKSTUR CITRA KERABANG DENGAN METODE HUE, SATURATION, VALUE," pp. 9–14, 2020.
- [13] Z. F. Abror, "KLASIFIKASI CITRA KEBAKARAN DAN NON KEBAKARAN MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK," vol. 24, no. 100, pp. 102–113, 2019.
- [14] D. H. Firdaus, ImranBahtiar, L. D. Bakti, and E. Suryadi, "KLASIFIKASI PENYAKIT KATARAK PADA MATA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK ( CNN ) BERBASIS WEB WEB-BASED CLASSIFICATION OF CATARACT IN THE EYES USING CONVOLUTIONAL NEURAL NETWORK ( CNN ) METHOD," vol. 1, no. 3, 2022.
- [15] M. F. Naufal *et al.*, "Klasifikasi Citra Game Batu Kertas Gunting Menggunakan Convolutional Neural Network," vol. 20, no. 1, pp. 166–174, 2021.
- [16] A. S. Riyadi, I. Puspa, and S. Widayati, "KLASIFIKASI CITRA ANJING DAN KUCING MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK ( CNN )," vol. 5, pp. 2–6, 2021.

**Conflict of Interest Statement:**

*The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.*