



Klasifikasi Batu Permata Berbasis Citra Menggunakan Convolutional Neural Network

Perani Rosyani*, Oke Hariansyah, Yuda Permadi, Muhamad Rosdiana, Nanang

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

Jl. Raya Puspitek No.46, Serpong, Kota Tangerang Selatan, Banten 15316, Indonesia

Email: ¹*dosen00837@unpam.ac.id, ²dosen00840@unpam.ac.id, ³dosen02953@unpam.ac.id, ⁴dosen02354@unpam.ac.id, ⁵dosen02599@unpam.ac.id

Email Penulis Korespondensi: dosen00837@unpam.ac.id

Submitted: 04/01/2026; Accepted: 14/01/2026; Published: 14/01/2026

Abstrak—Identifikasi batu permata secara manual masih menghadapi berbagai keterbatasan, seperti subjektivitas penilaian dan ketergantungan pada pengalaman ahli, sehingga berpotensi menimbulkan kesalahan klasifikasi, terutama pada batu permata dengan karakteristik visual yang mirip. Penelitian ini bertujuan untuk menerapkan *Convolutional Neural Network* (CNN) dalam melakukan klasifikasi citra batu permata berbasis visual secara otomatis pada dataset berukuran terbatas. Dataset yang digunakan terdiri dari citra tiga jenis batu permata, yaitu Alexandrite, Almandine, dan Amazonite, dengan distribusi data yang seimbang. Tahap pra-pemrosesan meliputi penyeragaman ukuran citra, normalisasi nilai piksel, serta augmentasi citra untuk meningkatkan variasi data. Model CNN yang dikembangkan merupakan arsitektur kustom yang terdiri dari tiga lapisan konvolusi dengan fungsi aktivasi ReLU, diikuti *max pooling*, *fully connected layer* dengan *dropout*, dan *output layer* menggunakan fungsi aktivasi *Softmax*. Evaluasi performa dilakukan menggunakan *confusion matrix* dan metrik klasifikasi berupa *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa model CNN mampu mencapai akurasi sebesar 93,33% pada data uji terbatas dengan performa klasifikasi yang relatif seimbang antar kelas. Namun, analisis kurva pelatihan dan validasi mengindikasikan adanya *overfitting*, yang menunjukkan bahwa kemampuan generalisasi model terhadap data baru masih terbatas. Temuan ini menegaskan bahwa nilai akurasi yang tinggi bersifat kondisional terhadap karakteristik dataset yang digunakan. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas jumlah dan keberagaman dataset, menerapkan strategi regularisasi yang lebih efektif, serta memanfaatkan pendekatan *transfer learning* guna meningkatkan stabilitas dan kemampuan generalisasi model..

Kata Kunci: Klasifikasi Citra; Batu Permata; Convolutional Neural Network; Deep Learning; Computer Vision

Abstract—Manual gemstone identification still faces several limitations, such as subjective assessment and strong dependence on expert experience, which may lead to misclassification, particularly for gemstones with similar visual characteristics. This study aims to apply a *Convolutional Neural Network* (CNN) for automatic visual-based gemstone image classification using a limited dataset. The dataset consists of three gemstone classes, namely Alexandrite, Almandine, and Amazonite, with a balanced class distribution. Image preprocessing includes image resizing, pixel value normalization, and data augmentation to increase data variability. The proposed CNN model is a custom architecture composed of three convolutional layers with ReLU activation, followed by max pooling, a fully connected layer with dropout, and a Softmax output layer. Model performance is evaluated using a confusion matrix and classification metrics, including accuracy, precision, recall, and F1-score. Experimental results show that the CNN model achieves a testing accuracy of 93.33% on the limited test dataset with relatively balanced performance across classes. However, analysis of the training and validation curves indicates the presence of *overfitting*, suggesting that the model's generalization capability to unseen data remains limited. These findings highlight that the achieved accuracy is conditional on the specific and constrained dataset used. Therefore, future work is recommended to expand dataset size and diversity, apply more comprehensive data augmentation strategies, and explore *transfer learning* approaches to improve model stability and generalization performance.

Keywords: Image Classification; Gemstone; Convolutional Neural Network; Deep Learning; Computer Vision

1. PENDAHULUAN

Identifikasi batu permata merupakan proses penting dalam bidang mineralogi dan industri perhiasan karena berkaitan langsung dengan nilai ekonomi, keaslian material, dan kualitas produk.[1] Pada praktiknya, proses identifikasi batu permata masih banyak dilakukan secara manual oleh ahli gemologi melalui pengamatan visual terhadap warna, tekstur, dan pola permukaan. Pendekatan ini sangat bergantung pada pengalaman individu, bersifat subjektif, serta berpotensi menimbulkan kesalahan, terutama ketika batu permata memiliki karakteristik visual yang mirip. Kondisi tersebut mendorong perlunya sistem otomatis yang mampu melakukan klasifikasi batu permata secara objektif dan konsisten.[2]

Perkembangan *artificial intelligence*, khususnya pada bidang *computer vision*, membuka peluang untuk menyelesaikan permasalahan tersebut melalui pemanfaatan citra digital.[3] Salah satu pendekatan yang banyak digunakan dalam klasifikasi citra adalah *deep learning*[4], terutama *Convolutional Neural Network* (CNN), yang memiliki kemampuan unggul dalam mengekstraksi fitur visual secara otomatis dari data mentah [5]. CNN telah terbukti efektif dalam berbagai aplikasi klasifikasi citra, seperti pengenalan objek, analisis medis[6], pertanian cerdas, hingga identifikasi material. Keunggulan CNN terletak pada kemampuannya mempelajari pola kompleks berupa warna[7], tekstur[8], dan bentuk[9] tanpa memerlukan proses ekstraksi fitur manual.[10], [11]

Namun, keunggulan tersebut dibarengi dengan tingkat kompleksitas model yang tinggi, di mana arsitektur CNN umumnya terdiri dari jutaan parameter yang harus dipelajari selama proses pelatihan. Kondisi ini



menyebabkan CNN sangat bergantung pada ketersediaan data dalam jumlah besar agar mampu membangun representasi fitur yang stabil dan bersifat general. Pada skenario dataset berukuran kecil atau kurang bervariasi, model CNN cenderung menyesuaikan bobot jaringan secara berlebihan terhadap data pelatihan, sehingga hanya menghafal pola spesifik alih-alih mempelajari karakteristik umum data. Fenomena ini meningkatkan risiko terjadinya *overfitting*, yang ditandai dengan kesenjangan performa antara data pelatihan dan data validasi atau data uji.

Oleh karena itu, penerapan CNN pada dataset terbatas tidak hanya menjadi persoalan implementasi teknis, tetapi juga tantangan metodologis yang penting untuk dianalisis, terutama dalam memahami perilaku pembelajaran model, batasan kemampuan generalisasi, serta faktor-faktor yang memengaruhi perbedaan performa antara data pelatihan dan validasi.

Beberapa penelitian terdahulu telah mengkaji penerapan *computer vision* dan *deep learning*, khususnya Convolutional Neural Network (CNN), dalam klasifikasi citra batu permata dan material mineral. Chow dan Reyes-Aldasoro mengembangkan pendekatan klasifikasi batu permata berbasis citra menggunakan kombinasi fitur warna dan tekstur serta algoritma *machine learning* dan *deep learning*. Hasil penelitian tersebut menunjukkan bahwa metode berbasis citra mampu menghasilkan performa yang sebanding, bahkan sedikit lebih baik, dibandingkan identifikasi oleh gemolog berpengalaman, meskipun akurasi menurun ketika jumlah data uji terbatas dan kelas memiliki kemiripan visual tinggi [12]

Dalam konteks klasifikasi material permata yang lebih spesifik, penelitian Zou et al.[13] mengombinasikan *hyperspectral imaging* dengan *deep learning* berbasis CNN untuk membedakan jadeite tipe A dan B. Hasil penelitian menunjukkan bahwa pemanfaatan fitur spektral dan tekstural secara bersamaan mampu meningkatkan akurasi klasifikasi secara signifikan dibandingkan metode *machine learning* konvensional, sekaligus memberikan interpretabilitas terhadap fitur yang dipelajari model

Selain itu, penelitian[14] oleh Hardman et al. dalam *Gems & Gemology* menegaskan bahwa pendekatan *machine learning* dan *deep learning* memiliki keunggulan dalam klasifikasi material permata, termasuk alexandrite, berlian, dan mutiara, terutama dalam mengolah data kompleks berbasis citra dan spektrum. Namun, studi tersebut juga menekankan bahwa model dengan kompleksitas tinggi, seperti CNN, berpotensi mengalami *overfitting* apabila diterapkan pada dataset berukuran kecil atau kurang bervariasi

Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa CNN merupakan metode yang efektif untuk klasifikasi batu permata berbasis citra, khususnya dalam memanfaatkan karakteristik warna dan tekstur. Namun demikian, keterbatasan jumlah dan variasi data masih menjadi tantangan utama yang dapat memengaruhi kemampuan generalisasi model. Meskipun demikian, masih relatif sedikit penelitian yang membahas secara eksplisit keterbatasan model CNN dan faktor penyebab terjadinya perbedaan performa antara data pelatihan dan data validasi.[15] Oleh karena itu, penelitian ini berfokus pada penerapan CNN pada dataset batu permata dengan jumlah terbatas, sekaligus menganalisis dampak keterbatasan data terhadap performa dan potensi terjadinya *overfitting* sebagai celah penelitian.

Meskipun secara umum batu permata memiliki ribuan jenis dengan karakteristik visual yang sangat beragam, penelitian ini dibatasi pada klasifikasi tiga jenis batu permata, yaitu Alexandrite, Almandine, dan Amazonite. Pemilihan ketiga jenis tersebut didasarkan pada ketersediaan data citra serta perbedaan karakteristik visual utama berupa warna dan tekstur permukaan. Dengan adanya pembatasan jumlah kelas ini, penelitian difokuskan pada evaluasi efektivitas Convolutional Neural Network (CNN) dalam mengklasifikasikan batu permata pada skala kompleksitas terbatas, sekaligus menganalisis dampak keterbatasan data terhadap performa dan generalisasi model.

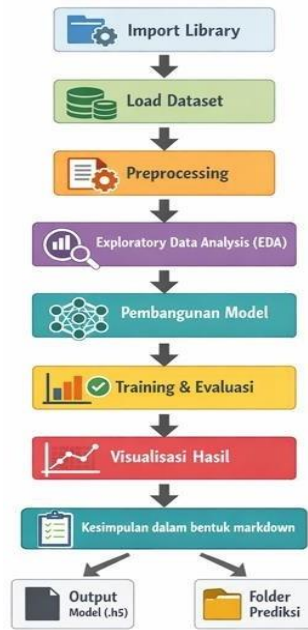
Oleh karena itu, penelitian ini bertujuan untuk mengimplementasikan *Convolutional Neural Network* dalam klasifikasi citra batu permata berbasis gambar digital serta mengevaluasi kinerja model pada dataset dengan jumlah data terbatas. Penelitian ini diharapkan dapat memberikan gambaran mengenai efektivitas[16] CNN dalam mengklasifikasikan batu permata, sekaligus mengidentifikasi keterbatasan model sebagai dasar pengembangan penelitian lanjutan dengan arsitektur dan dataset yang lebih optimal.

2. METODOLOGI PENELITIAN

Pendekatan yang digunakan dalam penelitian ini adalah *deep learning* [17] dengan algoritma *Convolutional Neural Network* (CNN), yang dipilih karena kemampuannya dalam mengekstraksi fitur visual secara otomatis dari citra. Seluruh tahapan penelitian dirancang secara berurutan, mulai dari pengumpulan data, pra-processing citra, pembangunan model, hingga evaluasi performa, sehingga hasil yang diperoleh dapat dianalisis dan dipertanggungjawabkan secara ilmiah.

2.1 Tahapan Penelitian

Tahapan penelitian dilakukan secara sistematis untuk memastikan penerapan metode CNN dapat menyelesaikan permasalahan klasifikasi batu permata sesuai dengan tujuan penelitian. Alur penelitian secara umum meliputi beberapa tahapan utama sebagai berikut pada Gambar 1.



Gambar 1. Alur Penelitian

Dataset yang digunakan dalam penelitian ini terdiri dari total 135 citra batu permata, yang terbagi ke dalam tiga kelas, yaitu Alexandrite, Almandine, dan Amazonite, dengan masing-masing kelas berjumlah 45 citra. Permasalahan yang dikaji merupakan *multi-class classification* dengan tiga kelas pada skala dataset terbatas, yang secara inheren meningkatkan risiko terjadinya *overfitting* pada model CNN.

Pada tahap pra-processing, seluruh citra diseragamkan ke dalam ukuran input yang sama sesuai dengan kebutuhan arsitektur CNN, dilakukan normalisasi nilai piksel ke rentang [0,1], serta diterapkan teknik *image augmentation* seperti rotasi dan flipping untuk meningkatkan variasi data dan mengurangi kecenderungan model menghafal pola spesifik data pelatihan[18].

Dataset kemudian dibagi ke dalam dua subset utama, yaitu data pelatihan dan data pengujian. Sebanyak 90 citra (30 citra per kelas) digunakan sebagai data pelatihan, sedangkan 45 citra (15 citra per kelas) digunakan sebagai data pengujian. Selain itu, sebagian data pelatihan digunakan sebagai data validasi melalui mekanisme *validation split*[19] selama proses pelatihan, yang bertujuan untuk memantau perilaku pembelajaran model dan mendeteksi potensi terjadinya *overfitting*. [20]

Data uji digunakan secara terpisah untuk mengevaluasi kemampuan generalisasi model terhadap data yang tidak pernah dilibatkan dalam proses pelatihan.

2.2 Arsitektur Model CNN

Arsitektur CNN yang digunakan dalam penelitian ini dirancang secara *custom* dengan mempertimbangkan ukuran dataset yang terbatas, sehingga kompleksitas model tetap terkendali. Model CNN terdiri dari tiga convolutional layer, di mana setiap lapisan menggunakan kernel berukuran 3×3 untuk mengekstraksi fitur lokal dari citra input. Setiap convolutional layer diikuti oleh ReLU (Rectified Linear Unit) sebagai fungsi aktivasi dan max pooling layer berukuran 2×2 untuk mereduksi dimensi fitur serta menekan kompleksitas komputasi. [21].

Setelah tahap ekstraksi fitur, hasil *feature map* diratakan menggunakan *flatten layer* dan diteruskan ke fully connected layer sebagai tahap klasifikasi. Untuk mengurangi risiko *overfitting*, diterapkan dropout layer dengan nilai 0,5 pada bagian fully connected layer. Lapisan output menggunakan fungsi aktivasi Softmax, yang sesuai untuk permasalahan klasifikasi multikelas dengan tiga kelas, sehingga model menghasilkan probabilitas keanggotaan untuk setiap kelas batu permata [22]. Dengan konfigurasi tersebut, model CNN mampu mengekstraksi fitur visual secara hierarkis sekaligus menjaga keseimbangan antara kapasitas model dan keterbatasan jumlah data.



Gambar 2. Arsitektur CNN

2.3 Pelatihan dan Evaluasi Model

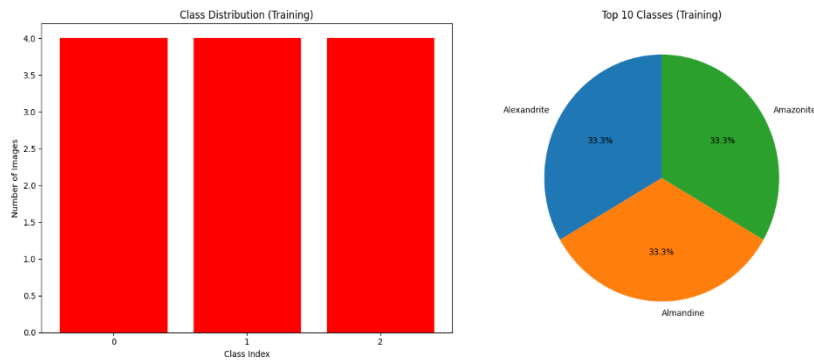
Proses pelatihan model CNN dilakukan menggunakan pendekatan *supervised learning*. Model dioptimasi menggunakan optimizer Adam, yang dipilih karena kemampuannya dalam menyesuaikan laju pembelajaran secara adaptif dan stabil pada dataset berukuran kecil. Fungsi loss yang digunakan adalah Categorical Crossentropy, yang umum digunakan pada permasalahan klasifikasi multikelas. Pelatihan model dilakukan selama 50 epoch, dengan pemantauan performa pada data validasi di setiap epoch untuk mendeteksi potensi *overfitting*. Evaluasi akhir model dilakukan menggunakan data uji dengan menghitung metrik klasifikasi berupa accuracy, precision, recall, dan F1-score, serta dianalisis menggunakan confusion matrix untuk mengetahui distribusi kesalahan klasifikasi pada masing-masing kelas.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penerapan metode *Convolutional Neural Network* (CNN) dalam mengklasifikasikan citra batu permata serta pembahasan terhadap kinerja model yang dihasilkan. Penyajian hasil difokuskan pada karakteristik dataset, performa klasifikasi per kelas, serta analisis perilaku model berdasarkan metrik evaluasi dan visualisasi hasil pelatihan. Pembahasan dilakukan secara analitis dengan mengaitkan hasil eksperimen dan keterbatasan model yang ditemukan selama proses penelitian.


3.1 Karakteristik Dataset dan visualisasi data

Dataset yang digunakan dalam penelitian ini terdiri dari citra batu permata yang terbagi ke dalam tiga kelas utama, yaitu Alexandrite, Almandine, dan Amazonite, dengan distribusi data yang relatif seimbang pada masing-masing kelas. Distribusi yang seimbang ini memungkinkan evaluasi performa model dilakukan secara objektif tanpa adanya dominasi kelas tertentu, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Distribusi Kelas Dataset

Perbedaan karakteristik visual antar kelas menjadi tantangan utama dalam proses klasifikasi. Bisa dilihat pada gambar 4. Alexandrite memiliki ciri perubahan warna yang dipengaruhi kondisi pencahayaan, Almandine didominasi warna merah gelap hingga ungu, sedangkan Amazonite memiliki karakteristik warna hijau kebiruan dengan guratan putih. Variasi visual tersebut menjadi dasar bagi model CNN dalam mempelajari fitur pembeda antar kelas selama proses pelatihan.

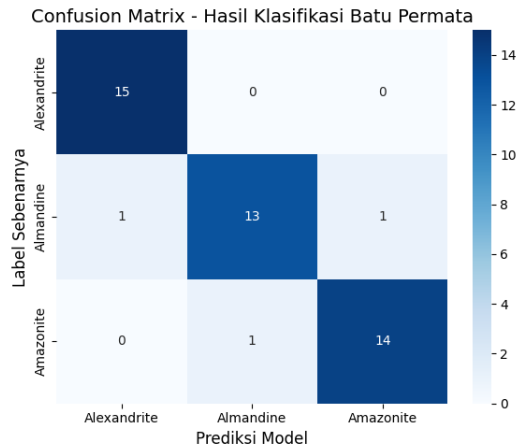


Gambar 4. Sample dari setiap kelas

3.2 Hasil Pengujian dan Evaluasi Model

Model CNN dalam penelitian ini dilatih menggunakan 90 citra data latih yang terbagi secara seimbang ke dalam tiga kelas (masing-masing 30 citra per kelas). Jumlah data latih yang relatif terbatas ini menjadi faktor penting yang memengaruhi perilaku pembelajaran model, khususnya terkait kecenderungan terjadinya *overfitting*, sebagaimana dianalisis pada kurva pelatihan dan validasi[23].

3.2.1 Confusion Matrix



Gambar 5. Confusion Matrix

Hasil pengujian model CNN menggunakan data uji divisualisasikan melalui *confusion matrix* pada Gambar 5, yang memberikan gambaran rinci mengenai performa klasifikasi pada masing-masing kelas. Data uji yang digunakan berjumlah 45 citra, masing-masing terdiri dari 15 citra Alexandrite, 15 citra Almandine, dan 15 citra Amazonite.

Pada kelas Alexandrite, model berhasil mengklasifikasikan seluruh 15 citra secara benar tanpa kesalahan prediksi ke kelas lain. Hal ini menunjukkan bahwa karakteristik visual Alexandrite dapat dikenali dengan baik oleh model CNN. Untuk kelas Almandine, model menghasilkan 13 prediksi benar, sementara 2 citra mengalami kesalahan klasifikasi, masing-masing diprediksi sebagai Alexandrite dan Amazonite. Kesalahan ini mengindikasikan bahwa Almandine merupakan kelas dengan tingkat kemiripan visual tertinggi terhadap kelas lain, terutama akibat variasi pencahayaan dan intensitas warna. Sementara itu, pada kelas Amazonite, model berhasil mengklasifikasikan 14 citra secara benar, dengan 1 citra salah diprediksi sebagai Almandine, dan tidak ditemukan kesalahan prediksi ke kelas Alexandrite.

Perhitungan akurasi pengujian dilakukan dengan membandingkan jumlah prediksi benar terhadap total data uji, yang secara matematis dirumuskan sebagai berikut:

$$Accuracy = \left(\frac{\text{Total Prediksi Benar}}{\text{Total Data Uji}} \right) \times 100\%$$

$$Accuracy = \left(\frac{42}{45} \right) \times 100\% = 93,33\%$$

Berdasarkan jumlah prediksi benar sebanyak 42 dari 45 citra, diperoleh nilai akurasi pengujian sebesar 93,33%. Nilai ini menunjukkan bahwa model CNN memiliki kemampuan klasifikasi yang sangat baik pada data uji terbatas. Namun demikian, tingginya akurasi pengujian perlu diinterpretasikan secara hati-hati dengan mempertimbangkan distribusi kesalahan antar kelas dan hasil evaluasi pada data validasi.[24]

3.2.2 Evaluasi Precision, Recall dan F1-Score

Berdasarkan confusion matrix pada Gambar 5, nilai metrik precision, recall, dan F1-score dihitung secara langsung sebagai turunan dari distribusi prediksi pada masing-masing kelas. Pada kelas Alexandrite, seluruh 15 citra uji berhasil diklasifikasikan dengan benar tanpa adanya kesalahan prediksi, sehingga diperoleh nilai precision, recall, dan F1-score sebesar 1,00.

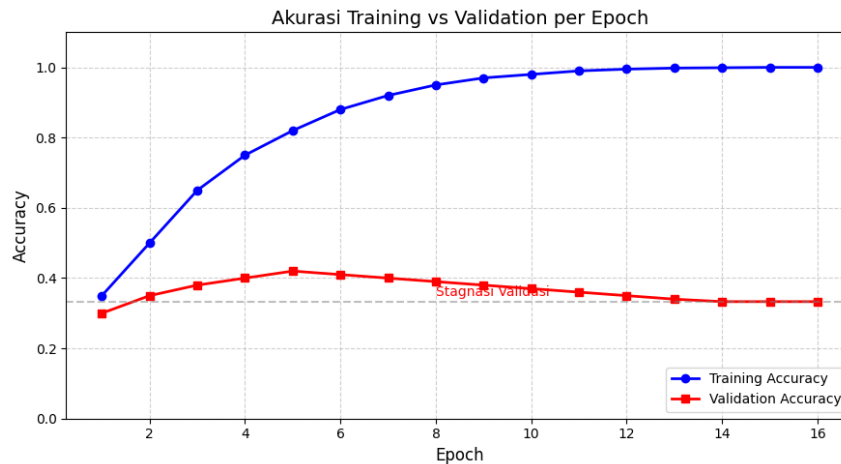
Pada kelas Almandine, dari 15 citra uji, sebanyak 13 citra berhasil diklasifikasikan dengan benar, sementara 2 citra mengalami kesalahan prediksi. Kondisi ini menghasilkan nilai precision dan recall yang lebih rendah dibandingkan kelas lainnya. Sementara itu, pada kelas Amazonite, model menghasilkan 14 prediksi benar dan 1 kesalahan klasifikasi, yang menunjukkan performa klasifikasi yang relatif stabil namun masih dipengaruhi oleh kemiripan visual antar kelas.

Secara keseluruhan, nilai precision, recall, dan F1-score yang diperoleh berada pada kisaran 0,87–1,00, yang konsisten dengan nilai akurasi pengujian sebesar 93,33%. Hal ini menunjukkan bahwa performa model pada

data uji terbatas tergolong tinggi dan stabil, meskipun perbedaan performa antar kelas masih terlihat akibat kemiripan karakteristik visual dan keterbatasan data latih.

3.2.3 Analisis Kurva pelatihan dan validasi

Berdasarkan hasil visualisasi yang diperoleh dari tahap proses pelatihan dan evaluasi, dilakukan analisis terhadap kurva akurasi dan *loss* untuk memahami perilaku model pada gambar 7 sebagai berikut:



Gambar 7. Hasil training dan validation

Berdasarkan Gambar 7, indikasi *overfitting* mulai terlihat pada sekitar epoch ke-6 hingga ke-8, ketika akurasi pelatihan terus meningkat secara signifikan, sementara akurasi validasi mencapai titik maksimum dan kemudian cenderung stagnan bahkan menurun. Pola ini menunjukkan bahwa setelah beberapa epoch awal, model mulai menghafal pola data latih tanpa diikuti peningkatan kemampuan generalisasi pada data validasi.

Meskipun telah diterapkan teknik regularisasi berupa dropout dengan nilai 0,5, strategi tersebut belum sepenuhnya mampu menekan terjadinya *overfitting*. Hal ini terutama disebabkan oleh jumlah dan variasi data latih yang terbatas, sehingga model dengan kapasitas tinggi seperti CNN tetap rentan menghafal data. Selain itu, mekanisme *early stopping* tidak diterapkan dalam penelitian ini, sehingga proses pelatihan tetap berlangsung hingga epoch terakhir dan memperkuat kecenderungan *overfitting* yang teramati pada kurva pelatihan dan validasi.

3.3 Pembahasan

Hasil penelitian menunjukkan bahwa *Convolutional Neural Network* efektif dalam mengekstraksi fitur visual citra batu permata dan menghasilkan performa klasifikasi yang tinggi pada data uji terbatas. Keunggulan CNN terletak pada kemampuannya mempelajari fitur kompleks seperti warna dan tekstur tanpa memerlukan ekstraksi fitur manual, sehingga sangat sesuai untuk permasalahan klasifikasi citra berbasis visual.

Namun demikian, perbedaan yang signifikan antara performa pelatihan dan validasi menunjukkan bahwa model masih mengalami *overfitting*. Kondisi ini menegaskan bahwa meskipun model mampu mengenali pola data latih dengan sangat baik, kemampuan generalisasi terhadap data baru masih terbatas. Temuan ini sejalan dengan penelitian terdahulu yang menyatakan bahwa CNN cenderung rentan terhadap *overfitting* ketika diterapkan pada dataset berukuran kecil.

Kesalahan klasifikasi yang paling sering terjadi pada kelas Almandine dapat dikaitkan dengan karakteristik visual citra yang didominasi oleh warna merah gelap hingga ungu dengan tingkat saturasi tinggi. Pada beberapa citra, intensitas warna yang gelap menyebabkan berkurangnya kontras antara objek batu permata dan latar belakang, sehingga fitur visual yang diekstraksi oleh CNN menjadi kurang diskriminatif. Selain itu, variasi pencahayaan pada proses pengambilan citra berpotensi menghasilkan kemiripan pola warna dan tekstur dengan citra Alexandrite atau Amazonite pada kondisi tertentu. Faktor-faktor tersebut menyebabkan model mengalami kesulitan dalam membedakan Almandine secara konsisten dibandingkan dua kelas lainnya.

Keterbatasan utama penelitian ini terletak pada jumlah dan variasi dataset yang belum sepenuhnya merepresentasikan kompleksitas visual batu permata. Oleh karena itu, peningkatan performa model pada penelitian selanjutnya dapat dilakukan melalui penambahan jumlah data, penerapan teknik augmentasi citra yang lebih beragam, serta eksplorasi pendekatan *transfer learning* untuk meningkatkan kemampuan generalisasi model.

4. KESIMPULAN

Penelitian ini berhasil menerapkan *Convolutional Neural Network* (CNN) sebagai pendekatan klasifikasi citra batu permata berbasis visual untuk mengatasi keterbatasan identifikasi manual yang bersifat subjektif dan bergantung pada pengalaman individu. Berdasarkan hasil pengujian pada dataset yang terbatas dan terkontrol, model CNN



mampu mencapai akurasi klasifikasi sebesar 93,33%, dengan kinerja yang relatif seimbang pada metrik precision, recall, dan F1-score pada sebagian besar kelas batu permata. Hasil ini menunjukkan bahwa CNN efektif dalam mengekstraksi fitur visual seperti warna dan tekstur pada skenario dataset spesifik dengan jumlah dan variasi data yang terbatas. Namun demikian, analisis kurva pelatihan dan validasi menunjukkan adanya perbedaan performa yang signifikan antara data pelatihan dan data validasi, yang mengindikasikan terjadinya *overfitting*. Kondisi ini menunjukkan bahwa meskipun model mampu mempelajari pola data latih dengan sangat baik dan menghasilkan performa tinggi pada data uji terbatas, kemampuan generalisasi model terhadap data baru masih belum optimal. Temuan ini menegaskan bahwa nilai akurasi yang tinggi perlu diinterpretasikan secara hati-hati dan tidak dapat dijadikan satu-satunya indikator keberhasilan model tanpa mempertimbangkan stabilitas performa pada data validasi. Keterbatasan utama penelitian ini terletak pada jumlah dan variasi dataset citra batu permata yang relatif kecil, sehingga belum sepenuhnya merepresentasikan kompleksitas karakteristik visual di dunia nyata. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas jumlah dan keberagaman data, menerapkan teknik augmentasi citra yang lebih komprehensif, serta mengeksplorasi pendekatan *transfer learning* guna meningkatkan kemampuan generalisasi dan stabilitas model CNN dalam klasifikasi batu permata.

REFERENCES

- [1] A. Demény *et al.*, “Provenance groups in a Roman jet jewelry collection at Aquincum (Budapest, Hungary) and comparison with jet and jet-like gemstones,” *J Archaeol Sci Rep*, vol. 54, pp. 1–9, Apr. 2024, doi: 10.1016/j.jasrep.2024.104413.
- [2] M. K. E. Putri, “Identifikasi Citra Batu Mulia dengan Menggunakan Metode Jaringan Saraf Tiruan Backpropagation,” *Eksplora Informatika*, vol. 9, no. 1, pp. 11–16, Sep. 2019, doi: 10.30864/eksplora.v9i1.256.
- [3] A. Tatar, M. Haghighi, and A. Zeinijahromi, “Experiments on image data augmentation techniques for geological rock type classification with convolutional neural networks,” *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 17, no. 1, pp. 106–125, Jan. 2025, doi: 10.1016/j.jrmge.2024.02.015.
- [4] S. Shrivastav, V. Jindal, and R. Eswarawaka, “A Fusion Method for Detection and Classification of Diseases in Tomato Plants Using Swarm-based Deep Learning,” *International Journal of Experimental Research and Review*, vol. 45, pp. 135–152, 2024, doi: 10.52756/ijerr.2024.v45spl.011.
- [5] Y. Li *et al.*, “Utilizing artificial intelligence to determine bone mineral density using spectral CT,” *Bone*, vol. 192, pp. 1–8, Mar. 2025, doi: 10.1016/j.bone.2024.117321.
- [6] J. Wang, Y. He, L. Yan, S. Chen, and K. Zhang, “Predicting Osteoporosis and Osteopenia by Fusing Deep Transfer Learning Features and Classical Radiomics Features Based on Single-Source Dual-energy CT Imaging,” *Acad Radiol*, vol. 31, no. 10, pp. 4159–4170, Oct. 2024, doi: 10.1016/j.acra.2024.04.022.
- [7] R. Fahrza Taufiqurrahman, F. T. Anggraeny, and A. N. Sihananto, “Penerapan Arsitektur CNN-Dilated untuk Deteksi Manipulasi Citra Deepfake,” *ILKOMNIKA: Journal of Computer Science and Applied Informatics E*, vol. 7, no. 3, pp. 495–506, 2025, doi: 10.28926/ilkomnika.v7i3.821.
- [8] M. Rafi, A. Firdaus, R. Mardhiyyah, and F. I. Sanjaya, “Klasifikasi Citra Biji Kopi Sangrai Arabika dan Robusta Menggunakan Convolutional Neural Network,” *TIN: Terapan Informatika Nusantara*, vol. 6, no. 7, pp. 969–980, 2025, doi: 10.47065/tin.v6i7.8695.
- [9] R. Robianto, S. H. Sitorus, and U. Ristian, “Penerapan Metode Decision Tree Untuk Mengklasifikasikan Mutu Buah Jeruk Berdasarkan Fitur Warna Dan Ukuran,” *Coding Jurnal Komputer dan Aplikasi*, vol. 9, no. 01, p. 76, 2021, doi: 10.26418/coding.v9i01.45907.
- [10] L. S. Dias, J. Schmith, J. D. de Oliveira, E. M. Cardoso, and J. B. Copetti, “Convolutional neural network for flow boiling patterns classification,” *AI Thermal Fluids*, vol. 4, p. 100015, Dec. 2025, doi: 10.1016/j.aif.2025.100015.
- [11] F. Mahrus Fathoni, “Klasifikasi Penyakit Daun Tomat Menggunakan Algoritma K-NN Berdasarkan Ekstraksi Fitur GLCM dan LBP,” *Jurnal Teknik Informatika dan Teknologi Informasi*, vol. 4, no. 1, pp. 39–50, Jan. 2024, doi: 10.55606/jutiti.v4i1.3417.
- [12] B. H. Y. Chow and C. C. Reyes-Aldasoro, “Automatic gemstone classification using computer vision,” *Minerals*, vol. 12, no. 1, pp. 1–10, Jan. 2022, doi: 10.3390/min12010060.
- [13] Z. Yutian, L. Gaojie, and H. Yongling, “Jadeite material identification and automatic a/b classification model based on deep learning and hyperspectral imaging,” *Perinatal Journal*, vol. 33, no. 1, pp. 1–10, 2025, doi: 10.57239/prn.25.033100112.
- [14] M. F. Hardman, A. Homkrajac, S. Eaton-Magaña, C. M. Breeding, A. C. Palke, and Z. Sun, “CLASSIFICATION OF GEM MATERIALS USING MACHINE LEARNING,” *Gems and Gemology*, vol. 60, no. 3, pp. 306–329, Sep. 2024, doi: 10.5741/GEMS.60.3.306.
- [15] J. Ver Berne, S. B. Saadi, N. Oliveira-Santos, L. E. Marinho-Vieira, and R. Jacobs, “Automated classification of panoramic radiographs with inflammatory periapical lesions using a CNN-LSTM architecture,” *J Dent*, vol. 156, pp. 1–9, May 2025, doi: 10.1016/j.jdent.2025.105688.
- [16] A. G. Akintola *et al.*, “Integrated deep learning paradigm for comprehensive lung cancer segmentation and classification using mask R-CNN and CNN models,” *Franklin Open*, vol. 11, pp. 1–9, Jun. 2025, doi: 10.1016/j.fraope.2025.100278.
- [17] P. I. Ritharson, K. Raimond, X. A. Mary, J. E. Robert, and A. J., “DeepRice: A deep learning and deep feature based classification of Rice leaf disease subtypes,” *Artificial Intelligence in Agriculture*, vol. 11, pp. 34–49, Mar. 2024, doi: 10.1016/j.aiaa.2023.11.001.
- [18] A. Ostreika, M. Pivoras, A. Misevičius, T. Skersys, and L. Paulauskas, “Classification of objects by shape applied to amber gemstone classification,” *Applied Sciences (Switzerland)*, vol. 11, no. 3, pp. 1–14, Feb. 2021, doi: 10.3390/app11031024.



- [19] Y. Xu and R. Goodacre, “On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning,” *J Anal Test*, vol. 2, no. 3, pp. 249–262, Jul. 2018, doi: 10.1007/s41664-018-0068-2.
- [20] F. Arif Prayogi, F. Hasim Arvianto, D. Rizki Pratama, and S. Sugiyanto, “Mushroom Classification Using Convolutional Neural Network MobileNetV2 Architecture for Overfitting Mitigation and Enhanced Model Generalization,” Aug. 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [21] K. Shahzad *et al.*, “Federated Convolutional Neural Networks (F-CNNs) for privacy-preserving multi-class skin lesion classification,” *Array*, p. 100667, Dec. 2025, doi: 10.1016/j.array.2025.100667.
- [22] O. Hariansyah, Y. Cahyono, and P. Rosyani, “Klasifikasi Penyakit Daun Pada Tanaman Terong dengan Metode K-Nearest Neighbors,” *Technology and Science (BITS)*, vol. 6, no. 4, pp. 2766–2775, 2025, doi: 10.47065/bits.v6i4.7016.
- [23] N. * Risky, D. Setiyawan, D. Hermawan, and O. Herdiyanto, “Prediksi Kelulusan Mahasiswa Menggunakan Algoritma Decision Tree C4.5 Berbasis Data Akademik dengan Validasi 10-Fold,” *TIN: Terapan Informatika Nusantara*, vol. 6, no. 6, pp. 670–678, Nov. 2025, doi: 10.47065/tin.v6i6.8662.
- [24] P. Rosyani, “Deteksi Citra Bunga Menggunakan Analisis Segmentasi Fuzzy C-Means dan Otsu Threshold,” *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, vol. 20, no. 1, pp. 27–34, Nov. 2020, doi: 10.30812/matrik.v20i1.715.