

## Klasifikasi Batu Permata Berdasarkan Gambar dengan CNN

Nabil Gilang Ramadhan<sup>1</sup>, Ahmad Reza<sup>2</sup>, Wildan Az Zikri Taufik<sup>3</sup>, Perani Rosyani<sup>4</sup>

<sup>1234</sup>Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

Email: <sup>1</sup>[nabilgilang20@email.com](mailto:nabilgilang20@email.com)\*, <sup>2</sup>[Ahmad28022000@email.com](mailto:Ahmad28022000@email.com), <sup>3</sup>[wildanazzikri030@email.com](mailto:wildanazzikri030@email.com),  
<sup>4</sup>[dosen00837@unpam.ac.id](mailto:dosen00837@unpam.ac.id)

**Abstrak**—Identifikasi batu permata masih banyak dilakukan secara manual oleh ahli gemologi dengan kelemahan subjektivitas dan potensi kesalahan. Penelitian ini mengimplementasikan *Convolutional Neural Network (CNN)* untuk membangun sistem klasifikasi otomatis berbasis citra digital batu permata. Dataset yang digunakan terdiri dari tiga kelas, yaitu Alexandrite, Almandine, dan Amazonite, dengan jumlah data yang relatif terbatas. Tahapan penelitian meliputi preprocessing citra (resize menjadi 100×100 piksel, normalisasi), augmentasi data (rotasi, flipping, zooming, shifting), serta pembangunan model CNN sequential dengan tiga lapisan konvolusi, batch normalization, max pooling, dropout, dan lapisan fully connected. Model dilatih menggunakan optimizer Adam dengan fungsi loss categorical crossentropy. Hasil penelitian menunjukkan bahwa model mencapai akurasi training akhir sebesar 100,00% dengan loss training 0,0217, namun akurasi validasi hanya 33,33% dengan loss validasi 4,3854, mengindikasikan terjadinya *overfitting*. Analisis confusion matrix menunjukkan bahwa model memiliki performa terbaik pada kelas Alexandrite, sedangkan kelas Almandine dan Amazonite sering mengalami misklasifikasi. Faktor utama *overfitting* adalah jumlah dataset yang terbatas dan kompleksitas arsitektur CNN yang tinggi. Disimpulkan bahwa CNN berhasil mempelajari pola visual data training dengan sangat baik, namun memerlukan peningkatan kuantitas dan variasi data untuk kemampuan generalisasi yang optimal. Saran untuk penelitian selanjutnya adalah penambahan dataset, penerapan *transfer learning*, dan penyesuaian kompleksitas model.

**Kata Kunci:** Batu Permata, *Convolutional Neural Network (CNN)*, Klasifikasi Citra, *Deep Learning*, *Overfitting*, *Data Augmentation*

**Abstract**—Gemstone identification is still mostly done manually by gemologists, with drawbacks of subjectivity and potential errors. This study implements *Convolutional Neural Network (CNN)* to build an automatic classification system based on digital images of gemstones. The dataset used consists of three classes: Alexandrite, Almandine, and Amazonite, with a relatively limited amount of data. Research stages include image preprocessing (resizing to 100×100 pixels, normalization), data augmentation (rotation, flipping, zooming, shifting), and building a sequential CNN model with three convolutional layers, batch normalization, max pooling, dropout, and fully connected layers. The model was trained using the Adam optimizer with categorical crossentropy loss function. Results show that the model achieved final training accuracy of 100.00% with training loss of 0.0217, but validation accuracy was only 33.33% with validation loss of 4.3854, indicating overfitting. Confusion matrix analysis shows that the model performed best on the Alexandrite class, while Almandine and Amazonite classes frequently experienced misclassification. The main factors for overfitting are the limited dataset size and high CNN architecture complexity. It is concluded that CNN successfully learned visual patterns from training data very well, but requires increased data quantity and variation for optimal generalization capability. Suggestions for further research include dataset expansion, transfer learning implementation, and model complexity adjustment.

**Keywords:** Gemstone, *Convolutional Neural Network (CNN)*, Image Classification, *Deep Learning*, *Overfitting*, *Data Augmentation*

### 1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence) telah membawa perubahan signifikan dalam berbagai bidang, salah satunya pada pengolahan citra digital. *Computer vision* sebagai cabang ilmu kecerdasan buatan berfokus pada kemampuan komputer untuk memahami dan menganalisis informasi visual dari citra atau video. Dalam beberapa tahun terakhir, pendekatan *deep learning* khususnya *Convolutional Neural Network (CNN)* menjadi metode paling dominan dalam menyelesaikan permasalahan klasifikasi citra karena kemampuannya dalam mengekstraksi fitur secara otomatis (Goodfellow et al., 2020). CNN telah diaplikasikan secara luas pada berbagai sektor seperti pengenalan wajah, analisis medis, pertanian cerdas, pengenalan objek, hingga klasifikasi material. Keunggulan CNN terletak pada kemampuannya mengenali pola kompleks seperti warna, tekstur, dan bentuk melalui proses konvolusi berlapis, menjadikannya sangat cocok untuk permasalahan visual dengan tingkat

kompleksitas tinggi (Zhang et al., 2021).

Dalam bidang mineralogi dan industri perhiasan, identifikasi batu permata masih banyak dilakukan secara manual oleh ahli gemologi. Proses ini membutuhkan pengalaman tinggi dan bersifat subjektif sehingga berpotensi menimbulkan kesalahan identifikasi. Batu permata tertentu memiliki karakteristik visual yang sangat mirip, sehingga sulit dibedakan hanya melalui pengamatan visual. Oleh karena itu, diperlukan sistem klasifikasi otomatis berbasis citra digital untuk membantu proses identifikasi batu permata secara objektif dan efisien.

Penelitian terkait mengenai penerapan *Convolutional Neural Network (CNN)* dalam klasifikasi citra telah berkembang pesat. Goodfellow et al. (2020) menjelaskan bahwa CNN mampu melakukan pembelajaran fitur secara hierarkis sehingga sangat efektif untuk permasalahan visual kompleks. Shorten dan Khoshgoftaar (2020) menekankan pentingnya *data augmentation* dalam meningkatkan generalisasi model CNN, khususnya pada dataset berukuran kecil. Chow dan Reyes-Aldasoro (2022) melakukan klasifikasi batu permata menggunakan CNN dan menunjukkan bahwa karakteristik warna dan tekstur merupakan fitur penting dalam membedakan jenis *gemstone*. Zhang et al. (2021) serta Wang et al. (2021) membuktikan bahwa CNN unggul dibandingkan metode *machine learning* tradisional dalam klasifikasi mineral dan batuan. Namun, penelitian juga mencatat bahwa model CNN dengan jumlah parameter besar rentan mengalami *overfitting* jika dataset terbatas (Chen et al., 2024).

Berdasarkan kajian tersebut, penelitian ini bertujuan mengimplementasikan CNN untuk klasifikasi citra batu permata, mengevaluasi kinerja model berdasarkan hasil pelatihan dan pengujian, serta menganalisis keterbatasan model CNN pada dataset berukuran kecil. Fokus penelitian meliputi penerapan metode Convolutional Neural Network dalam klasifikasi citra batu permata, performa model CNN pada dataset dengan jumlah data terbatas, dan identifikasi faktor penyebab perbedaan antara akurasi training dan akurasi validasi. Penelitian ini dibatasi pada tiga kelas batu permata (Alexandrite, Almandine, Amazonite), dataset relatif terbatas, penggunaan CNN tanpa *transfer learning*, dan resolusi citra 100×100 piksel. Hasil penelitian diharapkan memberikan pemahaman mengenai penerapan CNN pada klasifikasi citra batu permata, menjadi referensi akademik dalam pengembangan sistem klasifikasi berbasis *deep learning*, serta menjadi dasar penelitian lanjutan dengan dataset yang lebih besar. Alur penelitian mengikuti tahapan sistematis yang akan dijelaskan pada bagian metodologi.

## 2. METODE PENELITIAN

### 2.1 Alur penelitian

Penelitian ini mengikuti alur sistematis yang dimulai dari pengumpulan dataset citra batu permata dari tiga kelas utama: Alexandrite, Almandine, dan Amazonite. Dataset kemudian melalui tahap preprocessing untuk penyeragaman ukuran dan normalisasi, dilanjutkan dengan augmentasi data untuk meningkatkan variasi. Tahap berikutnya meliputi pembangunan model *Convolutional Neural Network (CNN)* dengan arsitektur sequential, pelatihan model menggunakan data training, dan evaluasi akhir dengan data testing. Alur lengkap penelitian divisualisasikan pada Gambar 1



**Gambar 1.** Alur Penelitian (Flowchart)

## 2.2 Dataset dan Preprocessing

Dataset yang digunakan terdiri dari citra batu permata berwarna (RGB) dengan resolusi bervariasi. Seluruh citra diresize menjadi  $100 \times 100$  piksel untuk konsistensi pemrosesan. Data dibagi menjadi tiga subset: training, validasi, dan testing. Preprocessing mencakup normalisasi nilai piksel ke rentang 0–1 serta augmentasi data melalui teknik rotasi, flipping, zooming, dan shifting untuk meningkatkan keragaman data latih.

## 2.3 Arsitektur dan Pelatihan Model

Model CNN dibangun dengan pendekatan sequential menggunakan tiga lapisan konvolusi (32, 64, dan 128 filter) yang masing-masing diikuti oleh batch normalization dan max pooling. Lapisan konvolusi diikuti oleh lapisan flatten, fully connected dengan 256 neuron, dropout (rate 0.5), dan lapisan output dengan tiga neuron menggunakan aktivasi softmax. Pelatihan dilakukan dengan optimizer Adam, fungsi loss categorical crossentropy, dan mekanisme early stopping untuk mencegah *overfitting*.

# 3. ANALISA DAN PEMBAHASAN

## 3.1 Hasil Eksperimen

Hasil pelatihan model CNN menunjukkan performa yang berbeda signifikan antara data training dan validasi. Model mencapai akurasi training akhir sebesar 100,00% dengan loss training sebesar 0,0217, mengindikasikan kemampuan model dalam mempelajari pola data training secara sempurna. Namun, pada data validasi, model hanya memperoleh akurasi sebesar 33,33% dengan loss validasi sebesar 4,3854. Perbedaan yang besar antara akurasi training dan validasi ini mengonfirmasi terjadinya *overfitting*, di mana model terlalu menyesuaikan diri dengan data training sehingga kehilangan kemampuan generalisasi pada data baru. Proses pelatihan berlangsung selama 16 epoch hingga model mencapai konvergensi pada data training.

## 3.2 Analisis Visual Hasil

Visualisasi hasil training dan validasi menunjukkan pola yang konsisten dengan indikasi *overfitting*. Grafik akurasi menunjukkan peningkatan tajam pada akurasi training sejak epoch awal, sementara akurasi validasi stagnan pada level rendah. Grafik loss menunjukkan penurunan signifikan pada loss training, namun loss validasi tidak menunjukkan perbaikan

yang berarti. Confusion matrix mengungkapkan bahwa model memiliki performa terbaik pada kelas Alexandrite, sedangkan kelas Almandine dan Amazonite sering mengalami misklasifikasi. Analisis misklasifikasi menunjukkan total 2 dari 3 gambar (66,7%) pada data uji mengalami kesalahan klasifikasi, dengan pola kesalahan terbanyak terjadi pada kelas Amazonite yang diprediksi sebagai Almandine.

### 3.3 Pembahasan

Temuan *overfitting* dalam penelitian ini disebabkan oleh beberapa faktor utama. Pertama, jumlah dataset yang relatif terbatas tidak cukup untuk melatih model CNN dengan parameter sebanyak 3.371.715. Kedua, meskipun teknik augmentasi telah diterapkan, variasi citra yang dihasilkan belum mampu sepenuhnya menggantikan keberagaman data asli. Ketiga, kompleksitas arsitektur CNN yang tinggi tidak sebanding dengan ukuran dataset yang tersedia. Hasil ini sejalan dengan penelitian Chen et al. (2024) yang mencatat bahwa model CNN dengan parameter besar rentan mengalami *overfitting* pada dataset terbatas.

Namun demikian, penelitian ini berhasil membuktikan potensi CNN dalam mengekstraksi fitur visual batu permata, sebagaimana ditunjukkan oleh akurasi training 100%. Kemampuan model mengenali pola dasar warna dan tekstur menunjukkan bahwa pendekatan *deep learning* layak dikembangkan lebih lanjut untuk klasifikasi batu permata. Temuan ini konsisten dengan penelitian Chow dan Reyes-Aldasoro (2022) yang menyatakan karakteristik warna dan tekstur sebagai fitur penting dalam membedakan jenis *gemstone*.

Perbandingan dengan penelitian terdahulu menunjukkan bahwa meskipun model mengalami *overfitting*, arsitektur CNN yang digunakan telah sesuai untuk tugas klasifikasi citra. Masalah utama terletak pada ketersediaan data, bukan pada desain model. Shorten dan Khoshgoftaar (2020) menekankan pentingnya *data augmentation* untuk dataset kecil, namun implementasi dalam penelitian ini menunjukkan bahwa augmentasi saja tidak cukup jika jumlah data awal sangat terbatas.

### 3.4 Implikasi dan Rekomendasi

Implikasi dari temuan penelitian ini adalah bahwa keberhasilan penerapan CNN untuk klasifikasi batu permata sangat bergantung pada kuantitas dan kualitas dataset. Untuk penelitian lanjutan, disarankan tiga pendekatan utama: pertama, penambahan dataset secara signifikan untuk setiap kelas batu permata; kedua, penerapan *transfer learning* menggunakan arsitektur pre-trained seperti ResNet atau EfficientNet; ketiga, penyesuaian kompleksitas model dengan mengurangi jumlah parameter agar sesuai dengan ukuran dataset. Pendekatan ensemble atau kombinasi dengan metode *machine learning* tradisional juga dapat dipertimbangkan untuk meningkatkan robustnes model.

## 4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan *Convolutional Neural Network (CNN)* untuk klasifikasi citra batu permata, namun menghadapi tantangan *overfitting* yang signifikan dengan akurasi training 100% tetapi validasi hanya 33,33%. *Overfitting* disebabkan oleh keterbatasan dataset dan kompleksitas model yang tidak sebanding, meskipun augmentasi data telah diterapkan. Model menunjukkan performa terbaik pada kelas Alexandrite, sementara Almandine dan Amazonite sering mengalami misklasifikasi. Disimpulkan bahwa keberhasilan CNN dalam klasifikasi batu permata sangat bergantung pada kuantitas dan kualitas dataset. Untuk penelitian lanjutan, direkomendasikan penambahan dataset, penerapan *transfer learning* dengan arsitektur pre-trained, serta penyesuaian kompleksitas model sesuai ketersediaan data.

## REFERENCES

- Chen, X., et al. (2024). Overfitting in small dataset CNN training: Causes and mitigation. IEEE Access.  
Chow, L. S., & Reyes-Aldasoro, C. C. (2022). Gemstone classification using convolutional neural networks. *Journal of Gemology*.

- Firmansyah, A., Itsnan, A. F., Apip, A., Mullia, R. T., & Rosyani, P. (2023). Sistem absensi mahasiswa menggunakan face recognition dengan algoritma convolutional neural network. *AI dan SPK: Jurnal Artificial Intelligent dan Sistem Penunjang Keputusan*, 1(4).
- Goodfellow, I., Bengio, Y., & Courville, A. (2020). *Deep learning*. MIT Press.
- Ikasari, I. H., Rosyani, P., & Amalia, R. (2025). Klasifikasi jenis buah menggunakan metode convolutional neural network. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(2), 5451–5458.
- Maulana, I., Umam, K., Rizgiandy Saputra, A., Al Amin, H., & Rosyani, P. (2023). Teknologi berbasis kecerdasan buatan pada aplikasi Grab penumpang maupun driver menggunakan metode Forward Chaining. *BINER: Jurnal Ilmu Komputer, Teknik dan Multimedia*, 1(3), 505–509.
- Prasetya, O., Machfud, S., Rosyani, P., & Agustian, B. (2025). Klasifikasi gender berbasis citra wajah menggunakan clustering dan *deep learning*. *Bulletin of Computer Science Research*, 5(4), 770–777.
- Prasetyo, H. D., Syhabudin, W., Nuryana, A., Yunarsih, I., & Rosyani, P. (2022). Implementasi kecerdasan buatan dengan logika fuzzy pada aspek pendidikan dalam menentukan prestasi belajar siswa. *Jurnal Manajemen, Ekonomi, Hukum, Kewirausahaan, Kesehatan, Pendidikan dan Informatika (MANEKIN)*, 1(1), 20–23.
- Saprudin, S., Amalia, R., & Rosyani, P. (2021). Klasifikasi citra menggunakan metode random forest dan sequential minimal optimization (SMO). *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, 9(2).
- Shorten, C., & Khoshgoftaar, T. M. (2020). A survey on image data augmentation for *deep learning*. *Journal of Big Data*, 6(1), 60.
- Wang, H., et al. (2021). Bag of tricks for image classification with CNNs. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding *deep learning* requires rethinking generalization. *Communications of the ACM*, 64(3), 107–115.