

# Klasifikasi Tekstur Kayu Jati dan Mahoni Menggunakan Ekstraksi Fitur GLCM dan Convolutional Neural Network (CNN)

Kalfin Syah Kilau Mayya<sup>1</sup>, Irsyad Fadhil Makarim<sup>2\*</sup>, Wisanggeni Atthoriq Kuswirasatya<sup>3</sup>, Eva Yulia Puspaningrum<sup>4</sup>

<sup>1,2,3,4</sup>Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

<sup>1</sup>[22081010251@student.upnjatim.ac.id](mailto:22081010251@student.upnjatim.ac.id)

<sup>2</sup>[22081010131@student.upnjatim.ac.id](mailto:22081010131@student.upnjatim.ac.id)

<sup>3</sup>[322081010127@student.upnjatim.ac.id](mailto:322081010127@student.upnjatim.ac.id)

<sup>4</sup>[evapuspaningrum.if@upnjatim.ac.id](mailto:evapuspaningrum.if@upnjatim.ac.id)

\*Corresponding author email: [22081010131@student.upnjatim.ac.id](mailto:22081010131@student.upnjatim.ac.id)

**Abstrak**— Identifikasi jenis kayu secara manual membutuhkan keahlian dan waktu, serta rentan subjektivitas. Penelitian ini mengusulkan sistem klasifikasi otomatis untuk tekstur kayu jati dan mahoni menggunakan kombinasi Convolutional Neural Network (CNN) untuk ekstraksi fitur visual dan Gray Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur tekstur. Dataset terdiri dari 220 citra (110 jati, 110 mahoni) yang melalui tahap pra-pemrosesan termasuk augmentasi data. Model yang dibangun memiliki dua input (citra dan fitur GLCM) yang digabungkan sebelum lapisan klasifikasi. Model dilatih selama 20 epoch dan dievaluasi menggunakan metrik akurasi, precision, recall, F1-score, serta confusion matrix. Hasil evaluasi menunjukkan performa yang baik dengan akurasi keseluruhan mencapai 93%. Model mampu mengklasifikasikan kayu jati dengan recall 100% dan Mahoni dengan recall 86%. Penggabungan CNN dan GLCM terbukti efektif meningkatkan akurasi klasifikasi tekstur kayu.

**Kata Kunci**— Klasifikasi Kayu, Tekstur Kayu, CNN, GLCM, Ekstraksi Fitur.

## I. PENDAHULUAN

Kayu merupakan salah satu material alam yang memiliki peran penting dalam kehidupan manusia, khususnya sebagai bahan baku dalam industri furnitur dan konstruksi. Setiap jenis kayu memiliki karakteristik visual yang unik, terutama pada pola-pola tekstur dan variasi warnanya. Perbedaan visual ini menjadi dasar untuk identifikasi jenis kayu, namun proses identifikasi secara manual seringkali membutuhkan keahlian khusus dan waktu yang tidak sedikit, serta rentan terhadap subjektivitas. Oleh karena itu, pengembangan sistem klasifikasi otomatis jenis kayu menjadi sebuah kebutuhan untuk mempermudah dan meningkatkan efisiensi proses identifikasi.

Metode Convolutional Neural Network (CNN) telah merevolusi bidang pengenalan pola dan klasifikasi citra dalam beberapa tahun terakhir, menunjukkan kinerja yang impresif dalam berbagai domain. Kemampuan CNN untuk mempelajari fitur-fitur hierarkis secara otomatis langsung dari data citra mentah menjadikannya sangat efektif. Dalam konteks

klasifikasi objek biologis dan alami, CNN telah banyak diterapkan. Sebagai contoh, Ilahiyah dan Nilogiri [1] berhasil mengimplementasikan deep learning menggunakan CNN untuk identifikasi jenis tumbuhan berdasarkan citra daun.

Dalam lingkup analisis citra kayu secara spesifik, CNN juga telah menunjukkan kontribusi yang signifikan. Christopher R. dan Sipayung [2] menerapkan arsitektur CNN untuk mengklasifikasikan empat jenis kayu pada furnitur, yaitu jati, mahoni, oak, dan pinus dengan dataset 120 citra hasil augmentasi dan akurasi yang dihasilkan adalah 80,5%. Lebih lanjut, Mustamin, Sari, dan Khatimi [3] menggunakan CNN untuk klasifikasi kualitas kayu kelapa, dan melaporkan rata-rata akurasi sebesar 84,89%. Tidak hanya untuk identifikasi jenis atau kualitas, CNN juga digunakan untuk aplikasi lain seperti deteksi cacat pada permukaan kayu. Riantiarni [4] memanfaatkan model CNN berbasis YOLOv5 untuk mendeteksi cacat pada permukaan kayu pinus dengan hasil mAP (mean Average Precision) yang baik, yaitu 94,3%. Rangkaian penelitian ini mempertegas kapabilitas CNN dalam menangani berbagai permasalahan terkait analisis citra kayu. Meskipun CNN sangat efektif dalam menangkap fitur-fitur spasial dan visual umum dari citra, analisis tekstur yang mendetail merupakan aspek krusial dalam identifikasi kayu. Tekstur kayu, yang terbentuk dari susunan sel dan serat, menyimpan informasi penting untuk membedakan jenis-jenis kayu. Gray Level Co-occurrence Matrix (GLCM) adalah metode ekstraksi fitur tekstur yang telah dikenal luas dan terbukti handal. GLCM bekerja dengan menganalisis hubungan spasial antar piksel berdasarkan nilai intensitas keabuan mereka, menghasilkan fitur-fitur statistik seperti kontras, korelasi, energi, dan homogenitas. Fitur-fitur ini secara kuantitatif merepresentasikan karakteristik tekstur citra. Penelitian ini berhipotesis bahwa dengan mengintegrasikan kemampuan CNN dalam ekstraksi fitur visual umum dengan kemampuan GLCM dalam ekstraksi fitur tekstur yang lebih eksplisit, model klasifikasi yang dihasilkan akan lebih robust dan akurat. Penambahan informasi tekstur dari GLCM

diharapkan dapat meningkatkan pemahaman model terhadap karakteristik permukaan kayu secara lebih komprehensif. Oleh karena itu, penelitian ini mengusulkan sebuah pendekatan untuk klasifikasi tekstur kayu jati dan mahoni dengan menggabungkan metode CNN dan ekstraksi fitur GLCM. Pemilihan kayu jati dan mahoni didasarkan pada nilai ekonomis tinggi dan penggunaannya yang luas di Indonesia, di mana identifikasi akurat seringkali diperlukan. Dengan mengkombinasikan keunggulan dari kedua metode tersebut, penelitian ini bertujuan untuk memberikan kontribusi dalam pengembangan sistem klasifikasi tekstur kayu yang lebih akurat dan dapat diandalkan untuk mendukung berbagai aplikasi praktis.

## II. LANDASAN TEORI

### A. Pengolahan Citra Digital

Pengolahan citra digital merupakan teknik yang memanfaatkan algoritma komputer untuk mengolah gambar digital sehingga informasi penting dapat diekstrak dari data citra. Citra digital terdiri atas susunan piksel (picture elements) dua dimensi, di mana setiap piksel memiliki koordinat spasial dan nilai intensitas tertentu. Proses pengolahan citra digital melibatkan tahapan berurutan mulai dari akuisisi citra, pra-pemrosesan (untuk mengurangi noise dan memperbaiki kualitas citra), peningkatan kontras atau ketajaman, segmentasi objek, kompresi data, representasi ciri, hingga pengenalan pola [5]. Tahapan-tahapan tersebut disesuaikan dengan tujuan aplikasi; misalnya, dalam klasifikasi tekstur citra, fokusnya adalah pada ekstraksi fitur tekstur yang tepat sebelum melakukan pengklasifikasian objek.

Salah satu aspek penting dalam ekstraksi fitur citra adalah analisis tekstur. Tekstur visual didefinisikan sebagai variasi spasial lokal dari elemen-elemen sederhana pada citra (misalnya variasi warna, orientasi, atau intensitas) yang dapat menggambarkan pola permukaan sebuah objek. Analisis tekstur pada citra sering dilakukan dengan menggunakan matriks ko-okkuren (Gray-Level Co-occurrence Matrix, GLCM) yang terkenal dalam pengolahan citra. GLCM menghitung distribusi kombinasi nilai piksel (level abu-abu) pada jarak dan arah tertentu dalam citra, sehingga mampu menangkap karakteristik pola tekstur permukaan objek [6]. Selain itu, teknik pembelajaran mendalam (deep learning) seperti Convolutional Neural Network (CNN) juga banyak digunakan untuk klasifikasi tekstur, karena model CNN mampu secara otomatis mengekstraksi fitur-fitur kompleks dari citra. Penggunaan CNN terbukti memberikan kinerja klasifikasi yang lebih baik dibandingkan metode konvensional seperti Local Binary Pattern (LBP), bahkan dengan jumlah data latih yang relatif kecil [7]. Dengan demikian, konsep-konsep dasar pengolahan citra digital (termasuk definisi piksel, tahapan pemrosesan citra, ekstraksi ciri tekstur seperti GLCM, dan penerapan CNN) menjadi landasan teori penting dalam penelitian klasifikasi tekstur kayu berbasis citra.

### B. Ekstraksi Fitur Tekstur Menggunakan GLCM

Gray-Level Co-Occurrence Matrix (GLCM) adalah teknik klasik untuk mengekstrak fitur tekstur dengan menghitung frekuensi kemunculan pasangan nilai piksel pada jarak dan orientasi tertentu. Metode ini diperkenalkan oleh Haralick et al. pada tahun 1973 dan hingga kini banyak digunakan dalam analisis citra tekstur [8]. GLCM menghasilkan matriks ko-occurrence tingkat keabuan sehingga dapat dihitung beragam fitur statistik seperti kontras, homogenitas, energi, korelasi, dan dissimilaritas untuk merepresentasikan karakteristik tekstur citra. Sebagai contoh, Iqbal et al. menggunakan GLCM untuk mengekstrak fitur tekstur pada citra penginderaan jauh dan mencatat bahwa metode ini merupakan teknik statistik yang banyak diterapkan pada pengolahan citra jarak jauh [9]. Berbagai penelitian menunjukkan bahwa penggunaan fitur GLCM pada tahap klasifikasi citra dapat meningkatkan akurasi model dibanding hanya menggunakan informasi citra skala abu-abu saja [10].

### C. Arsitektur CNN dalam Klasifikasi Citra

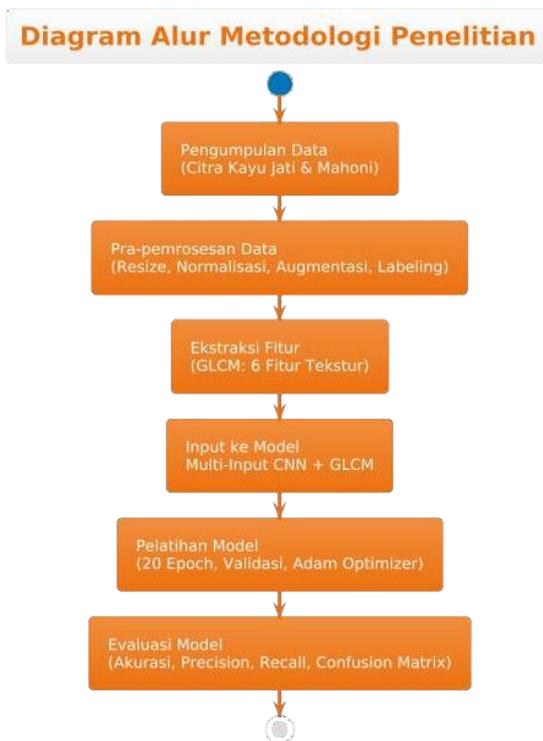
Jaringan Saraf Konvolusional (CNN) banyak digunakan dalam klasifikasi citra karena kemampuannya mengekstraksi fitur citra secara efektif pada dataset berskala besar. Arsitektur CNN tipikal terdiri atas beberapa lapisan berantai, termasuk lapisan konvolusi dengan kernel terlatih untuk mendeteksi fitur lokal (misalnya tepi, sudut, dan tekstur) dari citra input, lapisan pooling (seperti max-pooling atau global average pooling) untuk mereduksi dimensi spasial peta fitur sambil mempertahankan informasi utama, serta lapisan fungsi aktivasi (misalnya ReLU) dan lapisan fully-connected di akhir untuk melakukan klasifikasi. Setiap komponen arsitektur CNN tersebut dirancang agar jaringan dapat belajar representasi hierarkis citra secara otomatis tanpa perlu ekstraksi fitur manual [11]. Seiring kemajuan penelitian, bermacam arsitektur CNN baru telah dikembangkan untuk meningkatkan kinerja klasifikasi. Beberapa arsitektur terkenal antara lain AlexNet (2012), VGG, ResNet, DenseNet, hingga HRNet (2020), yang memperdalam jaringan dan memperkenalkan teknik seperti sambungan residual atau blok konvolusi berdimensi berbeda untuk meningkatkan akurasi [12]. Perkembangan arsitektur CNN selama lebih dari satu dekade ini menunjukkan bahwa pemilihan dan desain arsitektur sangat krusial dalam mencapai kinerja terbaik pada tugas klasifikasi citra [13].

### D. Penerapan GLCM + CNN dalam Penelitian Klasifikasi Tekstur

Beberapa penelitian terbaru menunjukkan bahwa penggabungan fitur tekstur GLCM (Gray-Level Co-Occurrence Matrix) dengan model CNN dapat meningkatkan akurasi klasifikasi tekstur. Sebagai contoh, Sagayaraj dan Devi (2025) memperkenalkan metode baru dengan menggabungkan fitur GLCM dan fitur-fitur dari model CNN berbasis transfer learning untuk klasifikasi kualitas kopra. Pendekatan ini menghasilkan akurasi klasifikasi sangat tinggi (sekitar 99,6%)

[14]. Demikian pula, Liu et al. (2021) mengusulkan model "Textured-DL" untuk deteksi kanker prostat, di mana matriks GLCM tiga dimensi diekstraksi dari patch volumetrik MRI lesi prostat, kemudian GLCM tersebut digabungkan dan diumpankan ke CNN guna menghitung probabilitas keberadaan kanker [15]. Selain itu, Sudhakar et al. (2023) menggunakan GLCM sebagai tahap seleksi fitur awal sebelum klasifikasi, dengan menerapkan CNN pada citra Pap smear. Mereka melaporkan bahwa model hybrid GLCM-CNN menghasilkan presisi tertinggi dalam deteksi kanker serviks [16]. Hasil-hasil ini mengindikasikan bahwa integrasi fitur tekstur GLCM ke dalam arsitektur CNN dapat memperkaya informasi tekstur mikroskopis yang dipelajari dan pada akhirnya meningkatkan kinerja klasifikasi visual.

### III. METODOLOGI PENELITIAN



Gbr. 1 Diagram Alur Metodologi Penelitian.

Alur metodologi penelitian ini dimulai dari tahap pengumpulan data, di mana citra tekstur kayu Jati dan Mahoni diperoleh secara manual. Selanjutnya, dilakukan pra-pemrosesan data mencakup pelabelan, perubahan ukuran citra, normalisasi, dan augmentasi untuk meningkatkan kualitas serta keberagaman data latih. Tahap berikutnya adalah ekstraksi fitur tekstur menggunakan GLCM yang menghasilkan enam parameter statistik dari masing-masing citra. Data citra dan fitur GLCM tersebut kemudian dijadikan input ke dalam model klasifikasi, dengan pendekatan multi-input yang menggabungkan arsitektur CNN dan jaringan dense untuk fitur GLCM. Model kemudian dilatih selama 20 epoch dengan

validasi terhadap data uji di setiap epoch. Terakhir, dilakukan evaluasi model melalui metrik akurasi, precision, recall, f1-score, confusion matrix, dan grafik histori pelatihan untuk menilai performa klasifikasi secara menyeluruh.

#### A. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri atas citra tekstur dua jenis kayu, yaitu kayu jati dan kayu mahoni. Sebanyak 220 citra berhasil dikumpulkan secara manual melalui pencarian dan pengunduhan dari Google Images, dengan distribusi seimbang yaitu 110 citra kayu jati dan 110 citra kayu mahoni. Citra-citra ini menjadi dasar untuk proses pelatihan dan pengujian model klasifikasi.

#### B. Pra-pemrosesan Data

Pra-pemrosesan citra dilakukan untuk menyiapkan data sebelum digunakan dalam pelatihan model. Langkah pertama adalah pelabelan, di mana citra diberi label numerik: label 0 untuk kayu jati dan label 1 untuk kayu mahoni. Selanjutnya, semua citra diubah ukurannya menjadi resolusi tetap  $224 \times 224$  piksel agar sesuai dengan arsitektur model CNN. Proses normalisasi dilakukan dengan membagi nilai piksel dengan 255.0 agar berada dalam rentang  $[0, 1]$ . Untuk meningkatkan keragaman data latih dan mengurangi risiko overfitting, dilakukan augmentasi citra menggunakan beberapa teknik seperti rotasi ( $\text{rotation\_range} = 20$ ), translasi horizontal dan vertikal ( $\text{width\_shift\_range}$  dan  $\text{height\_shift\_range} = 0.2$ ), shear ( $\text{shear\_range} = 0.2$ ), zoom ( $\text{zoom\_range} = 0.2$ ), dan pembalikan horizontal ( $\text{horizontal\_flip} = \text{True}$ ), dengan mode pengisian piksel menggunakan metode 'nearest'.

#### C. Ekstraksi Fitur GLCM

Untuk mendapatkan informasi tekstur tambahan dari setiap citra, dilakukan ekstraksi fitur menggunakan metode Gray-Level Co-occurrence Matrix (GLCM). Langkah pertama adalah konversi citra dari format RGB ke grayscale. Setelah itu, level intensitas dikurangi menjadi 8 tingkat dengan membagi nilai piksel dengan 32. Matriks GLCM dihitung menggunakan jarak 1 piksel dan empat sudut orientasi ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ ), serta dinormalisasi dan disimetrisasi. Dari matriks tersebut, enam fitur statistik diekstrak: contrast, dissimilarity, homogeneity, energy, correlation, dan ASM (Angular Second Moment). Nilai rata-rata dari keempat arah tersebut digunakan sebagai nilai akhir dari masing-masing fitur.

#### D. Pengembangan Model

Model klasifikasi yang dikembangkan menggunakan pendekatan multi-input, menggabungkan fitur citra melalui arsitektur Convolutional Neural Network (CNN) dan fitur statistik GLCM melalui jaringan dense. Input pertama adalah citra berukuran  $224 \times 224$  piksel dengan tiga saluran warna, sementara input kedua berupa vektor GLCM berukuran 6. Arsitektur CNN terdiri dari empat lapisan Conv2D dengan jumlah filter berturut-turut 32, 64, 128, dan 128, menggunakan ukuran kernel  $3 \times 3$  dan fungsi aktivasi ReLU, masing-masing

diikuti oleh lapisan MaxPooling2D berukuran  $2 \times 2$ . Hasil akhir dari CNN diratakan (Flatten), lalu diproses melalui dua lapisan Dense dengan 512 dan 64 neuron (aktivasi ReLU). Sementara itu, fitur GLCM diproses melalui satu lapisan Dense dengan 16 neuron dan fungsi aktivasi ReLU. Kedua output dari cabang CNN dan GLCM digabungkan melalui lapisan concatenate dan dilanjutkan ke lapisan Dense output dengan 2 neuron dan fungsi aktivasi softmax untuk klasifikasi dua kelas. Model dikompilasi menggunakan optimizer Adam, fungsi loss `categorical_crossentropy`, dan metrik evaluasi `accuracy`.

#### E. Pelatihan Model

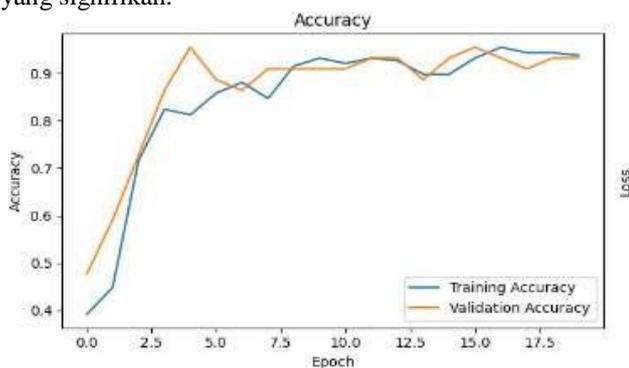
Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan nilai `random_state = 42` untuk menjamin reproduktifitas hasil. Label dikonversi ke format kategorikal sebelum digunakan. Model dilatih menggunakan data latih selama 20 epoch, dengan ukuran batch (batch size) yang telah ditentukan. Augmentasi diterapkan pada data citra selama pelatihan, sementara fitur GLCM digunakan langsung tanpa augmentasi. Selama pelatihan, data uji digunakan sebagai data validasi untuk memantau performa model di setiap akhir epoch.

#### F. Evaluasi Model

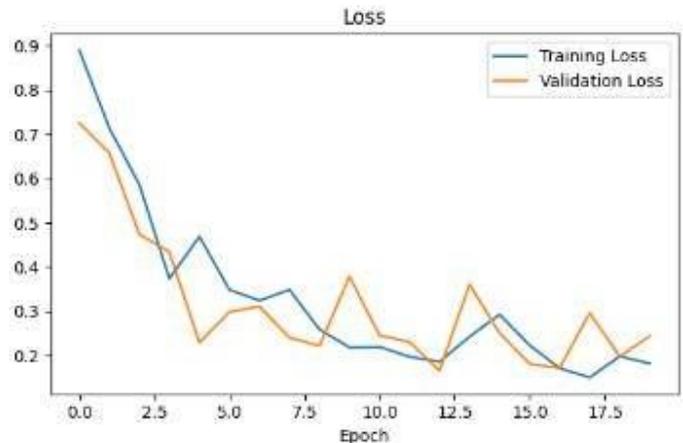
Setelah pelatihan selesai, model dievaluasi menggunakan data uji. Evaluasi dilakukan melalui prediksi kelas pada data uji dan perhitungan metrik performa seperti akurasi keseluruhan, precision, recall, dan f1-score untuk masing-masing kelas. Selain itu, confusion matrix digunakan untuk mengevaluasi jumlah klasifikasi yang benar dan salah secara visual. Grafik riwayat akurasi dan loss selama pelatihan dan validasi juga dibuat untuk menilai stabilitas pelatihan. Seluruh hasil evaluasi dan visualisasi disimpan sebagai file gambar untuk dokumentasi.

### IV. HASIL DAN PEMBAHASAN

Proses pelatihan model dilakukan selama 20 epoch dengan menggunakan kombinasi arsitektur CNN dan fitur GLCM sebagai input. Berdasarkan grafik histori akurasi dan loss yang ditunjukkan pada Gambar 1, model menunjukkan peningkatan performa secara konsisten. Akurasi pada data latih meningkat secara bertahap hingga mencapai 87,29% dengan nilai loss sebesar 0,2618 pada akhir pelatihan. Sementara itu, akurasi pada data validasi mencapai 93,18% dengan nilai loss 0,2390. Grafik akurasi dan loss menunjukkan kurva yang konvergen antara data latih dan validasi, yang mengindikasikan bahwa model belajar dengan stabil dan tidak mengalami overfitting yang signifikan.



Gbr. 2 Grafik histori akurasi selama pelatihan model.



Gbr. 3 Grafik histori loss selama pelatihan model.

Evaluasi model pada data uji menghasilkan akurasi keseluruhan sebesar 93%. Laporan klasifikasi menunjukkan performa yang sangat baik, terutama pada kelas kayu Jati yang memiliki precision 0,88, recall 1,00, dan f1-score 0,94. Untuk kelas kayu Mahoni, precision mencapai 1,00, recall sebesar 0,86, dan f1-score 0,93. Nilai recall yang tinggi pada kelas Jati menunjukkan bahwa hampir semua citra Jati dikenali dengan benar, sedangkan precision yang tinggi pada kelas Mahoni menunjukkan bahwa semua prediksi Mahoni oleh model benar adanya. Hasil confusion matrix menunjukkan bahwa seluruh citra kayu Jati (22 sampel) diklasifikasikan dengan benar, sementara 3 dari 22 citra kayu Mahoni diklasifikasikan keliru sebagai Jati. Hal ini mengindikasikan bahwa model lebih andal dalam mengenali tekstur kayu Jati dibandingkan Mahoni. Salah satu kemungkinan penyebab kesalahan klasifikasi ini adalah adanya kemiripan karakteristik visual antara beberapa sampel Mahoni dan Jati, seperti pola serat yang halus dan arah serat yang serupa. Selain itu, tekstur kayu Mahoni cenderung memiliki variasi yang lebih besar antar sampel, baik dari segi intensitas warna maupun kehalusan permukaan, sehingga menyulitkan model untuk menangkap pola yang konsisten. Variabilitas ini berpotensi menurunkan kemampuan generalisasi model pada kelas Mahoni. Kemungkinan lain adalah distribusi dalam dataset Mahoni yang mungkin lebih heterogen dibanding Jati, sehingga fitur yang dipelajari model belum cukup merepresentasikan seluruh spektrum tekstur Mahoni. Secara keseluruhan, kombinasi CNN dan GLCM terbukti efektif dalam meningkatkan akurasi klasifikasi. CNN berperandam mengekstrak fitur visual spasial, sementara GLCM memberikan informasi statistik tekstur yang bersifat komplementer. Penggabungan kedua jenis fitur ini memungkinkan model membangun representasi yang lebih menyeluruh terhadap karakteristik permukaan kayu. Hasil visualisasi grafik serta metrik evaluasi mendukung kesimpulan bahwa model yang dikembangkan bersifat robust, generalisasi baik, dan memiliki potensi untuk diterapkan dalam klasifikasi tekstur kayu secara otomatis.

Jika dibandingkan dengan penelitian sebelumnya, model yang diusulkan dalam penelitian ini menunjukkan peningkatan performa. Misalnya, penelitian oleh Christopher dan Sipayung (2023) yang mengklasifikasikan empat jenis kayu dengan arsitektur CNN menghasilkan akurasi sebesar 80,5%. Sementara itu, Mustamin et al. (2021) melaporkan akurasi rata-rata 84,89% dalam klasifikasi kualitas kayu kelapa menggunakan CNN. Dalam konteks ini, akurasi sebesar 93% yang dicapai oleh model gabungan CNN dan GLCM pada penelitian ini menunjukkan peningkatan kinerja yang signifikan. Hal ini menguatkan hipotesis bahwa integrasi fitur visual (CNN) dan fitur tekstur statistik (GLCM) memberikan kontribusi nyata dalam meningkatkan kemampuan klasifikasi tekstur kayu.

## V. KESIMPULAN

Penelitian ini berhasil mengembangkan sebuah model klasifikasi untuk tekstur kayu jati dan mahoni dengan mengintegrasikan metode Convolutional Neural Network (CNN) dan ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM). Model yang diusulkan menunjukkan kinerja yang baik dengan mencapai akurasi keseluruhan sebesar 93% pada data uji. Hasil evaluasi menunjukkan bahwa model mampu mengidentifikasi kayu Jati dengan recall 100% dan kayu Mahoni dengan recall 86% serta precision 100%. Penggabungan fitur visual yang diekstraksi oleh CNN dan fitur tekstur dari GLCM terbukti efektif dalam meningkatkan kemampuan diskriminatif model. Meskipun terdapat beberapa kesalahan klasifikasi pada kayu Mahoni, performa model secara umum dianggap berhasil dan menjanjikan. Penelitian ini memberikan kontribusi terhadap pengembangan sistem identifikasi kayu otomatis yang lebih akurat dan dapat diandalkan, yang berpotensi mendukung berbagai aplikasi praktis dalam industri perikanan. Penelitian selanjutnya dapat difokuskan pada peningkatan dataset, eksplorasi arsitektur model yang lebih lanjut, atau teknik fusi fitur yang lebih canggih untuk meningkatkan akurasi, khususnya untuk kelas yang memiliki variasi tekstur tinggi.

## REFERENSI

- [1] S. Ilahiyah dan A. Nilogiri, "Implementasi deep learning pada identifikasi jenis tumbuhan berdasarkan citra daun menggunakan convolutional neural network," *Justindo (Jurnal Sistem & Teknologi Informasi Indonesia)*, vol. 3, no. 2, hlm. 49-56, 2018.
- [2] E. Christopher R. and E. M. Sipayung, "Klasifikasi Image Jenis Kayu pada Furnitur dengan Convolutional Neural Network," *Jurnal Telematika*, vol. 18, no. 2, pp. 82-87, 2023.
- [3] N. F. Mustamin, Y. Sari, dan H. Khatimi, "Klasifikasi kualitas kayu kelapa menggunakan arsitektur CNN," *Kumpulan Jurnal Ilmu Komputer (KLIK)*, vol. 8, no. 1, hlm. 49-59, 2021.
- [4] T. Riantiarni, "Deteksi Cacat pada Permukaan Kayu Menggunakan Model Convolutional Neural Network Yolovs," *Skripsi, Telkom University, Bandung*, 2022.
- [5] B. Konara, M. Krishnapillai, and L. Galagedara, "Recent Trends and Advances in Utilizing Digital Image Processing for Crop Nitrogen Management," *Remote Sensing*, vol. 16, no. 23, p. 4514, Dec. 2024, doi: 10.3390/rs16234514.
- [6] K. Li, H. Yu, Y. Xu, and X. Luo, "Detection of oil spills based on gray level co-occurrence matrix and support vector machine," *Frontiers in Environmental Science*, vol. 10, Dec. 2022, doi: 10.3389/fenvs.2022.1049880.
- [7] O. Elezabi, S. Guesney-Bodet, and J.-B. Thomas, "Impact of Exposure and Illumination on Texture Classification Based on Raw Spectral Filter Array Images," *Sensors*, vol. 23, no. 12, p. 5443, Jun. 2023, doi: 10.3390/s23125443.
- [8] S. Barburiceanu, R. Terebes, and S. Meza, "3D Texture Feature Extraction and Classification Using GLCM and LBP-Based Descriptors," *Applied Sciences*, vol. 11, no. 5, p. 2332, Mar. 2021, doi: 10.3390/app11052332.
- [9] N. Iqbal, R. Mumtaz, U. Shafi, and S. M. H. Zaidi, "Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms," *PeerJ Computer Science*, vol. 7, p. e536, May 2021, doi: 10.7717/peerj-cs.536.
- [10] J. Liu et al., "Optimizing window size and directional parameters of GLCM texture features for estimating rice AGB based on UAVs multispectral imagery," *Frontiers in Plant Science*, vol. 14, Dec. 2023, doi: 10.3389/fpls.2023.1284235.
- [11] F. A. Mohammed, K. K. Tune, B. G. Assefa, M. Jett, and S. Muhie, "Medical Image Classifications Using Convolutional Neural Networks: A Survey of Current Methods and Statistical Modeling of the Literature," *Machine Learning and Knowledge Extraction*, vol. 6, no. 1, pp. 699-736, Mar. 2024, doi: 10.3390/make6010033.
- [12] L. Alzubaidi et al., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [13] [1]K. Kanwal et al., "Efficient CNN architecture with image sensing and algorithmic channeling for dataset harmonization," *Scientific Reports*, vol. 15, no. 1, p. 7552, Mar. 2025, doi: 10.1038/s41598-025-90616-w.
- [14] A. S. Sagayaraj and T. K. Devi, "Combination of gray level features with deep transfer learning for copra classification using machine learning and neural networks," *Scientific Reports*, vol. 15, no. 1, p. 1579, Jan. 2025, doi: 10.1038/s41598-025-85490-5.
- [15] Y. Liu et al., "Textured-Based Deep Learning in Prostate Cancer Classification with 3T Multiparametric MRI: Comparison with PI-RADS- Based Classification," *Diagnostics*, vol. 11, no. 10, p. 1785, Sep. 2021, doi: 10.3390/diagnostics11101785.
- [16] [1]K. Sudhakar et al., "Optimised feature selection-driven convolutional neural network using gray level co-occurrence matrix for detection of cervical cancer," *Open Life Sciences*, vol. 18, no. 1, Nov. 2023, doi: 10.1515/biol-2022-0770.