

# Penerapan Metode Convotutional Neural Network Untuk Klasifikasi Jenis Kayu Menggunakan Inceptionv3

<sup>1</sup>M. Renhat Ade Prayogo, <sup>2</sup>Danar Putra Pamungkas, <sup>3</sup>Patmi Kasih

<sup>1</sup>Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: <sup>1</sup>[mrenhat5@gmail.com](mailto:mrenhat5@gmail.com), <sup>2</sup>[danar@unpkediri.ac.id](mailto:danar@unpkediri.ac.id), <sup>3</sup>[fatkasih@gmail.com](mailto:fatkasih@gmail.com)

*Penulis Korespondens : M. Renhat Ade Prayogo*

**Abstrak**— Indonesia memiliki kekayaan jenis kayu yang sangat beragam, namun identifikasi manual sering terkendala kemiripan tekstur dan kurangnya pengetahuan masyarakat. Penelitian ini merancang sistem klasifikasi otomatis berbasis web menggunakan Convolutional Neural Network (CNN) dengan arsitektur InceptionV3. Sistem dikembangkan untuk mengklasifikasikan empat jenis kayu: akasia, glugu, jati, dan mahoni. Sebanyak 600 citra serat kayu dikumpulkan menggunakan kamera dan diproses melalui tahap normalisasi dan resize. Model CNN dilatih menggunakan transfer learning dengan bobot dari ImageNet. Hasil validasi menunjukkan akurasi klasifikasi mencapai 97,5%. Sistem ini mampu mengenali pola tekstur kayu secara efektif, memberikan solusi identifikasi yang otomatis, cepat, dan akurat. Hasil penelitian menunjukkan bahwa arsitektur InceptionV3 efektif digunakan dalam klasifikasi citra tekstur kayu.

**Kata Kunci**— CNN, InceptionV3, klasifikasi kayu, pengolahan citra

**Abstract**— Indonesia has a very diverse wealth of wood species, but manual identification is often hindered by similar textures and limited public knowledge. This study aims to develop an automatic web-based wood classification system using a Convolutional Neural Network (CNN) with the InceptionV3 architecture. The system is designed to classify four wood types: acacia, glugu, teak, and mahogany. A total of 600 wood grain images were collected using a camera and processed through normalization and resizing stages. The CNN model was trained using transfer learning with pre-trained weights from ImageNet. Validation results show that the model achieved a classification accuracy of 97.5%. The system effectively recognizes wood texture patterns, providing an automatic, fast, and accurate identification solution. The results demonstrate that the InceptionV3 architecture is effective for classifying wood texture images.

**Keywords**— CNN, InceptionV3, wood classification, image processing

This is an open access article under the CC BY-SA License.



## I. PENDAHULUAN

Indonesia dikenal sebagai negara yang kaya akan keanekaragaman jenis kayu, masing-masing memiliki karakteristik dan manfaat yang berbeda. Di antara banyaknya jenis kayu tersebut, hanya sebagian yang umum digunakan sebagai bahan untuk kerajinan tangan maupun konstruksi bangunan. Masyarakat kerap mencari jenis kayu yang memiliki tekstur menarik dan estetik, terutama untuk keperluan dekoratif dan bangunan. Namun, proses identifikasi jenis kayu secara manual sering kali menyulitkan karena banyaknya variasi tekstur dan corak yang tampak serupa, sehingga memicu kesalahan dalam pengenalan, terutama bagi masyarakat yang memiliki pengetahuan terbatas mengenai klasifikasi kayu [1].

Kesulitan ini diperparah oleh kemiripan tampilan antar jenis kayu dan kurangnya pengalaman dalam membedakan pola tekstur yang khas. Identifikasi manual pun memerlukan waktu yang cukup lama karena perlu dilakukan secara berulang demi memastikan jenis kayu yang benar [2]. Oleh karena itu, penelitian ini bertujuan untuk merancang sistem klasifikasi jenis kayu

berbasis website guna membantu pengguna dalam mengenali jenis kayu secara cepat, tepat, dan akurat.


Convolutional Neural Network (CNN) berperan penting dalam proses klasifikasi citra. Berdasarkan hasil penelitian sebelumnya, arsitektur GoogLeNet menunjukkan performa yang cukup baik dalam mengklasifikasikan kualitas kayu kelapa dengan akurasi rata-rata mencapai 84,89% pada berbagai lapisannya [3]. Sementara itu, model CNN berbasis YOLOv5 yang menggunakan fungsi aktivasi leaky ReLU (rectified linear unit) dan sigmoid mampu memberikan hasil terbaik pada klasifikasi dataset kayu pinus. Model YOLOv5s tanpa teknik penambahan citra (image enhancement) berhasil mencapai nilai mAP (mean Average Precision) sebesar 94,3% [4], menunjukkan ketepatan model dalam mendeteksi dan mengenali objek dengan presisi tinggi.

Dalam penelitian ini, proses klasifikasi citra tekstur kayu dilakukan dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) InceptionV3. Model InceptionV3 dipilih karena kemampuannya dalam mengekstraksi fitur-fitur visual secara efisien melalui struktur lapisan yang mendalam dan kompleks, sehingga mampu mengenali pola-pola halus pada tekstur kayu. Sistem klasifikasi ini dirancang untuk mengidentifikasi empat jenis kayu, yaitu kayu akasia, glugu, jati, dan mahoni dengan adanya Sistem ini diharapkan mampu memberikan solusi yang efektif dalam melakukan identifikasi jenis kayu secara otomatis melalui citra digital.

## II. METODE

### A. Pengumpulan Data

Dalam penelitian ini, dilakukan proses pengumpulan data merupakan tahap awal yang sangat krusial dalam sebuah penelitian, karena kualitas dataset yang diperoleh akan berpengaruh langsung terhadap keberhasilan seluruh proses analisis dan pemodelan di tahap berikutnya. Untuk menjamin keakuratan dan representasi data yang digunakan, pengambilan data dilakukan secara langsung dari sumber yang terpercaya dan relevan. Dalam penelitian ini, data dikumpulkan dari Mebel bayan kayu yang berlokasi di Kabupaten Nganjuk, Provinsi Jawa timur. Proses pengambilan citra dilakukan menggunakan kamera smartphone yang dilengkapi fitur ultra macro, dengan jarak pemotretan sekitar 8 cm dan posisi kamera tegak lurus terhadap permukaan objek guna memperoleh detail tekstur yang optimal. Selain itu, pencahayaan diatur secara cermat agar serat dan pola alami kayu dapat terekam dengan jelas dalam setiap citra yang diambil. Pendekatan ini bertujuan untuk menghasilkan dataset visual yang berkualitas tinggi dan mampu merepresentasikan ciri khas dari masing-masing jenis kayu secara akurat. Contoh hasil pengambilan citra serat kayu dapat dilihat pada Gambar 1.



Gambar 1. Data Citra Serat Kayu Akasia, Glugu, Jati, Mahoni

## B. Pre-processing Data

Dalam penelitian ini, dilakukan serangkaian proses pre-processing terhadap gambar kayu guna meningkatkan kualitas data sebelum dimasukkan ke dalam model. Tahapan ini bertujuan untuk memaksimalkan akurasi dan efisiensi model dalam mengidentifikasi berbagai jenis kayu. Pre-processing mencakup beberapa langkah penting, seperti pemberian label pada setiap gambar sesuai dengan jenis kayu yang diwakilinya, pembagian dataset menjadi data latih, validasi, dan uji, serta penyesuaian ukuran gambar agar seragam dan sesuai dengan kebutuhan input model [5] [6].

```

1  img_height, img_width = 224, 224
2  batch_size = 32
3  num_classes = 4 # jati, mahoni, akasia, glugu
4
5  train_datagen = ImageDataGenerator(
6      rescale=1./255,
7      rotation_range=20,
8      zoom_range=0.2,
9      horizontal_flip=True,
10 )
11
12 val_datagen = ImageDataGenerator(rescale=1./255)
13
14 img_size = (img_height, img_width)
15
16 train_generator = train_datagen.flow_from_directory(
17     TRAIN_DIR,
18     target_size=img_size,
19     batch_size=batch_size,
20     class_mode='categorical',
21     shuffle=True
22 )
23
24 val_generator = val_datagen.flow_from_directory(
25     VAL_DIR,
26     target_size=img_size,
27     batch_size=batch_size,
28     class_mode='categorical',
29     shuffle=False
30 )

```


Gambar 2. Proses Proses resize dan normalisasi

Pada Gambar 2, dilakukan proses normalisasi atau rescaling data guna menyesuaikan nilai piksel gambar agar seragam sebelum dilakukan penambahan data. Proses ini penting untuk memastikan konsistensi dalam pengolahan gambar dan meningkatkan kinerja model. Umumnya, gambar berwarna dalam format RGB (Red, Green, Blue) memiliki nilai piksel dalam rentang 0 hingga 255. Rentang nilai ini dapat memengaruhi hasil pelatihan model, karena variasi yang tinggi bisa menyebabkan ketidakseimbangan dalam proses pembelajaran. Oleh karena itu, dilakukan penskalaan nilai piksel dengan membaginya menggunakan faktor 1/255, sehingga seluruh nilai piksel berada dalam rentang 0 hingga 1. Hal ini membuat data menjadi lebih stabil dan mudah diproses oleh model selama pelatihan [7].

Selanjutnya, dataset yang telah dinormalisasi dibagi secara acak menjadi dua bagian untuk mendukung proses pembelajaran model. Sebanyak 80% dari data dialokasikan untuk data training, sementara 20% sisanya digunakan sebagai data validation. Data training mencakup sekitar 520 gambar kayu yang terbagi ke dalam 4 kategori jenis yang berbeda, dan digunakan untuk melatih model agar mampu mengenali pola-pola khas dari masing-masing jenis. Sementara itu, data validation yang terdiri dari 80 gambar berfungsi sebagai tolok ukur dalam proses pelatihan untuk menguji sejauh mana akurasi model dalam mengklasifikasikan gambar yang belum pernah dilihat sebelumnya [7].

Tahap berikutnya adalah melakukan penyesuaian ukuran (resize) terhadap seluruh gambar dalam dataset. Proses ini bertujuan untuk menyeragamkan dimensi gambar sehingga seluruh data input memiliki ukuran yang sama dan kompatibel dengan arsitektur model yang digunakan.


Ketidaksesuaian ukuran gambar dapat menyebabkan error atau penurunan performa selama pelatihan. Dalam penelitian ini, seluruh gambar diubah ukurannya menjadi 224x224 piksel, yang merupakan ukuran standar dalam banyak arsitektur CNN modern [7].



Gambar 3. kayu setelah dilakukan gambar hasil normalisasi & resize

### C. Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) adalah salah satu algoritma dalam deep learning yang termasuk dalam keluarga deep neural network, yang dirancang khusus untuk mengolah data berbentuk grid, seperti citra digital. CNN memiliki kemampuan untuk secara otomatis dan adaptif mengekstraksi fitur penting dari data input melalui serangkaian lapisan tersembunyi yang kompleks. Lapisan awal menerima gambar sebagai masukan, kemudian melewatkannya melalui beberapa tahap pemrosesan, seperti konvolusi, aktivasi, dan pooling, hingga akhirnya mencapai lapisan output yang melakukan klasifikasi berdasarkan fitur yang telah dipelajari. Komponen utama dari CNN adalah lapisan konvolusi yang berfungsi mendeteksi pola lokal pada gambar, seperti tepi, tekstur, atau bentuk, yang kemudian digabungkan untuk mengenali objek secara keseluruhan. Meskipun proses pelatihan model CNN dapat memakan waktu lama dan memerlukan perangkat keras berperforma tinggi, seperti GPU, hasil prediksinya sangat andal dan akurat, menjadikannya pilihan utama dalam berbagai aplikasi visi komputer seperti pengenalan wajah, klasifikasi objek, dan deteksi citra [8].



Gambar 4. Tahapan CNN [9]

### D. InceptionV3

Inception V3 merupakan salah satu arsitektur canggih dari Convolutional Neural Network (CNN) yang dikembangkan oleh Google dan dirancang khusus untuk menangani berbagai permasalahan dalam analisis citra serta deteksi objek. Arsitektur ini terkenal karena efisiensinya dalam mengolah informasi visual kompleks dengan tetap mempertahankan performa yang tinggi. Dalam proses pengolahan citra, algoritma Canny Edge Detector digunakan terlebih dahulu untuk mengekstraksi tepi objek secara efektif dari setiap gambar, sehingga memperkuat informasi fitur sebelum masuk ke dalam tahap pelatihan. Selanjutnya, teknik *transfer learning* diterapkan dengan memanfaatkan bobot-bobot terlatih dari model Inception V3 yang sebelumnya dilatih menggunakan dataset ImageNet [10].



Gambar 5. Model InceptionV3 [11]

Pada Gambar 5 menggambarkan arsitektur modul Inception yang memproses satu input melalui beberapa jalur paralel: konvolusi  $1 \times 1$ ,  $3 \times 3$ , dan  $5 \times 5$  (yang masing-masing didahului oleh konvolusi  $1 \times 1$  untuk mengurangi dimensi), serta jalur  $3 \times 3$  max pooling yang juga dilanjutkan dengan konvolusi  $1 \times 1$ . Output dari semua jalur ini kemudian digabungkan melalui proses concatenation. Pendekatan ini memungkinkan jaringan menangkap berbagai skala fitur secara efisien, sekaligus mengurangi beban komputasi dengan penggunaan konvolusi  $1 \times 1$  sebagai alat reduksi dimensi dan aktivasi. Hasilnya, representasi fitur menjadi lebih padat namun tetap informatif dan hemat sumber daya [11].

Model: "model"

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 224, 224, 3)]	0	[]
conv2d (Conv2D)	(None, 111, 111, 32)	864	['input_1[0][0]']
batch_normalization (Batch Normalization)	(None, 111, 111, 32)	96	['conv2d[0][0]']
activation (Activation)	(None, 111, 111, 32)	0	['batch_normalization[0][0]']
conv2d_1 (Conv2D)	(None, 109, 109, 32)	9216	['activation[0][0]']
batch_normalization_1 (Batch Normalization)	(None, 109, 109, 32)	96	['conv2d_1[0][0]']
activation_1 (Activation)	(None, 109, 109, 32)	0	['batch_normalization_1[0][0]']
conv2d_2 (Conv2D)	(None, 109, 109, 64)	18432	['activation_1[0][0]']
batch_normalization_2 (Batch Normalization)	(None, 109, 109, 64)	192	['conv2d_2[0][0]']
...			
Total params: 22065572 (84.17 MB)			
Trainable params: 262788 (1.00 MB)			
Non-trainable params: 21802784 (83.17 MB)			

Gambar 6. Arsitektur model dalam penelitian

Pada penelitian ini model ini diawali dengan lapisan input berukuran  $224 \times 224$  piksel dengan 3 saluran warna (RGB). Kemudian, model menerapkan beberapa blok Conv2D, masing-masing diikuti oleh normalisasi batch dan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas. Lapisan-lapisan ini bertujuan untuk mengekstraksi fitur dari citra masukan secara bertahap. Setelah serangkaian ekstraksi fitur, ditambahkan lapisan Dense dengan 128 unit yang menggunakan aktivasi ReLU untuk mendukung proses pembelajaran non-linear yang lebih kompleks. Untuk mencegah overfitting, digunakan lapisan Dropout dengan rasio 0.3 setelah setiap lapisan Dense. Model ini diakhiri dengan lapisan Dense berisi 12 neuron yang dilengkapi dengan fungsi aktivasi softmax, menandakan bahwa model dirancang untuk melakukan klasifikasi terhadap 4 kategori berbeda.



### III. HASIL DAN PEMBAHASAN

Dari hasil model klasifikasi citra ini dibangun menggunakan Convolutional Neural Network (CNN) dengan arsitektur InceptionV3. Implementasi dimulai dengan tahap preprocessing citra, di mana gambar kayu dimasukkan ke dalam model. Selanjutnya, model InceptionV3 digunakan untuk mengekstraksi fitur visual yang kompleks dari citra masing-masing jenis kayu. Hasil ekstraksi fitur tersebut kemudian diproses oleh lapisan-lapisan fully connected untuk menghasilkan prediksi akhir berupa kelas dari jenis kayu, yaitu Akasia, Glugu, Jati, atau Mahoni. Model dilatih dengan dataset citra berlabel dan dievaluasi menggunakan metrik akurasi, precision, recall, dan f1-score, untuk memastikan kemampuan terhadap data baru. Implementasi ini memungkinkan model untuk secara otomatis mengenali dan mengklasifikasikan gambar kayu.

#### A. Implementasi Model

```
1 model.compile(optimizer=Adam(learning_rate=0.0001),
2               loss='categorical_crossentropy',
3               metrics=['accuracy', tf.keras.metrics.Precision(), tf.keras.metrics.Recall()])
4
5 history = model.fit(
6     train_generator,
7     epochs=10,
8     validation_data=val_generator,
9     callbacks=[checkpoint]
10 )
```

Gambar 7. Model train


Pada Gambar 7 menunjukkan tahapan pelatihan model dalam mengenali pola visual dari gambar-gambar kayu. Pelatihan dilakukan selama 10 epoch, yaitu siklus penuh dari proses pembelajaran pada seluruh dataset training. Selama proses pelatihan, model dievaluasi menggunakan data training dan validation yang telah dibagi secara proporsional 80% untuk pelatihan dan 20% untuk validasi. Setelah proses pelatihan selesai, model diuji untuk memprediksi kelas dari gambar-gambar pada data validation. Hasil prediksi tersebut kemudian dibandingkan dengan label sebenarnya (ground truth) untuk menghitung berbagai metrik evaluasi, seperti precision, recall, f1-score, dan support. Metrik-metrik ini berperan penting dalam menilai performa dan efektivitas model dalam melakukan klasifikasi secara akurat.

#### B. Pengujian Model

Tabel 1 Hasil Pengujian Model

<i>Epoch</i>	<i>Data Train</i>		<i>Data Validation</i>	
	<i>Loss</i>	<i>Accuracy</i>	<i>Val Loss</i>	<i>Val Acc</i>
<b>1</b>	1.2564	0.4692	1.0592	0.6125
<b>2</b>	0.8108	0.7788	0.7641	0.8125
<b>3</b>	0.5721	0.8577	0.5581	0.9000
<b>4</b>	0.4460	0.9019	0.4339	0.9000
<b>5</b>	0.3567	0.9365	0.3448	0.9250
<b>6</b>	0.3072	0.9327	0.2993	0.9125
<b>7</b>	0.2745	0.9481	0.2485	0.9500
<b>8</b>	0.2232	0.9558	0.2136	0.9625
<b>9</b>	0.2159	0.9577	0.1960	0.9750
<b>10</b>	0.1846	0.9596	0.1784	0.9625

Tabel 1 menyajikan hasil pengujian model terhadap data pelatihan dan validasi. Berdasarkan hasil tersebut, terlihat bahwa model menunjukkan performa yang sangat baik, ditandai dengan peningkatan nilai accuracy dan penurunan nilai loss seiring bertambahnya jumlah epoch. Nilai accuracy mencerminkan tingkat keberhasilan model dalam melakukan klasifikasi secara tepat, sehingga dapat dijadikan indikator utama dalam mengevaluasi kelayakan model. Sementara itu, nilai loss menunjukkan besarnya kesalahan yang dibuat oleh jaringan, yang idealnya diminimalkan selama proses pelatihan. Pada data train, model berhasil mencapai akurasi tertinggi sebesar 95,96% dengan nilai loss terendah 0.1846. Sedangkan pada data validation, akurasi tertinggi yang dicapai adalah 97,50% dengan loss terendah sebesar 0.1784. Hasil ini menunjukkan bahwa model tidak hanya belajar dengan baik pada data pelatihan, tetapi juga mampu melakukan generalisasi yang baik terhadap data validasi. Visualisasi dari hasil pelatihan ini dapat dilihat melalui grafik yang menggambarkan perkembangan nilai accuracy dan loss pada kedua jenis data seiring dengan bertambahnya jumlah epoch.



Gambar 8. Grafik training accuracy Inceptionv3 dan Grafik training loss inceptionV3

Berdasarkan Gambar 8 terlihat adanya keterkaitan yang jelas antara jumlah epoch dengan nilai akurasi dan nilai loss pada data pelatihan maupun validasi. Seiring dengan bertambahnya jumlah epoch selama proses pelatihan, nilai akurasi pada data training dan validation cenderung mengalami peningkatan, yang menunjukkan adanya korelasi positif artinya, semakin lama model dilatih, semakin baik performanya dalam mengenali pola pada data. Sebaliknya, nilai loss menunjukkan tren yang menurun seiring dengan bertambahnya epoch, yang mencerminkan adanya korelasi negatif. Dengan kata lain, peningkatan jumlah epoch berkontribusi terhadap penurunan nilai loss baik pada data pelatihan maupun validasi, sehingga model menjadi lebih presisi dalam melakukan prediksi. Berdasarkan pola tersebut, dapat disimpulkan bahwa untuk memperoleh nilai loss yang lebih rendah dan meningkatkan nilai akurasi pada data training dan validasi, salah satu strategi yang dapat diterapkan adalah dengan menambah jumlah epoch selama proses pelatihan model.

### C. Precision Recall

Evaluasi kinerja model klasifikasi yang menggunakan arsitektur Inceptionv3 dalam mengidentifikasi berbagai jenis kayu dilakukan dengan mengukur sejumlah metrik performa. Metrik yang digunakan meliputi precision, recall, f1-score, dan support, yang masing-masing memberikan gambaran komprehensif mengenai kemampuan model dalam mengklasifikasikan data secara akurat. Precision menunjukkan sejauh mana model tepat dalam melakukan prediksi positif, recall menggambarkan seberapa baik model dalam menangkap seluruh data relevan, sementara f1-score merupakan keseimbangan antara precision dan recall. Support sendiri merepresentasikan jumlah data aktual untuk setiap kelas yang digunakan dalam evaluasi.

3/3 [=====] - 72s 13s/step


	precision	recall	f1-score	support
akasia	1.00	0.95	0.97	20
glugu	1.00	0.95	0.97	20
jati	0.91	1.00	0.95	20
mahoni	1.00	1.00	1.00	20
accuracy			0.97	80
macro avg	0.98	0.97	0.98	80
weighted avg	0.98	0.97	0.98	80

Gambar 9. Precision recall

Gambar di atas menunjukkan hasil evaluasi performa model klasifikasi menggunakan metrik precision, recall, f1-score, dan support untuk masing-masing kelas: akasia, glugu, jati, dan mahoni. Meskipun sebagian besar kelas mencatatkan nilai sempurna (1.00) pada precision dan recall, terdapat sedikit variasi pada kelas jati dan mahoni, dengan f1-score masing-masing sebesar 0.95 dan 1.00. Ini menunjukkan bahwa meskipun model sangat baik dalam mengenali sebagian besar kelas, terdapat beberapa prediksi yang kurang sempurna. Jumlah data untuk tiap kelas tetap seimbang, masing-masing 20 sampel. Secara keseluruhan, akurasi model mencapai 97%, didukung oleh nilai macro average dan weighted average sebesar 0.98 dan 0.98. Hasil ini mencerminkan performa model yang sangat baik, meskipun masih ada ruang untuk peningkatan pada kelas tertentu.

#### D. Hasil Klasifikasi

Klasifikasi dilakukan terhadap gambar yang berasal dari luar dataset pelatihan, Pada hasil klasifikasi yang ditampilkan pada Gambar 11, model berhasil mengenali jenis kayu pertama sebagai glugu dan kayu kedua sebagai jati. Hasil ini memberikan indikasi bahwa arsitektur Inceptionv3 memiliki performa yang baik dalam mengidentifikasi berbagai jenis kayu secara tepat, bahkan ketika dihadapkan dengan data baru yang belum pernah dilihat sebelumnya. Akurasi dalam prediksi ini memperkuat potensi penggunaan model dalam aplikasi pengenalan citra jenis kayu.



Gambar 10. Hasil klasifikasi gambar baru



#### IV. KESIMPULAN

Penelitian ini berhasil membangun sistem klasifikasi jenis kayu menggunakan metode CNN dengan arsitektur InceptionV3. Sistem ini mampu mengenali empat jenis kayu (akasia, glugu, jati, dan mahoni) dengan tingkat akurasi hingga 97,5% pada data uji. Model menunjukkan performa yang baik dalam mengenali gambar, bahkan pada gambar baru yang belum pernah dilatih sebelumnya. Hal ini membuktikan bahwa arsitektur InceptionV3 sangat efektif dalam mengenali tekstur kayu secara otomatis, dan berpotensi besar untuk diterapkan pada aplikasi nyata guna membantu proses identifikasi kayu dengan cepat dan efisien.

#### DAFTAR PUSTAKA

- [1] L. N. Raharjo, "Implementasi Algoritma Backpropagation Untuk Pengenalan Jenis Kayu," *Katalog.Ukdw.Ac.Id*, 2019.
- [2] D. W. Wibowo, D. Erwanto, and D. A. W. Kusumastutie, "Klasifikasi Jenis Kayu Menggunakan Ekstraksi Fitur Gray Level Co-Occurrence Matrix dan Multilayer Perceptron," *J. Nas. Tek. Elektro*, vol. 10, no. 1, p. 1, 2021, doi: 10.25077/jnte.v10n1.788.2021.
- [3] N. F. Mustamin, Y. Sari, and H. Khatimi, "Klasifikasi Kualitas Kayu Kelapa Menggunakan Arsitektur Cnn," *Klik - Kumpul. J. Ilmu Komput.*, vol. 8, no. 1, p. 49, 2021, doi: 10.20527/klik.v8i1.370.
- [4] F. AKHYAR, L. NOVAMIZANTI, and T. RIANTIARNI, "Sistem Inspeksi Cacat pada Permukaan Kayu menggunakan Model Deteksi Obyek YOLOv5," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 4, p. 990, 2022, doi: 10.26760/elkomika.v10i4.990.
- [5] N. D. Miranda, L. Novamizanti, and S. Rizal, "Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50," *J. Tek. Inform.*, vol. 1, no. 2, pp. 61–68, 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [6] C. Eva Sari Nainggolan, M. Nasir, Fatoni, and D. Udariansyah, "Perbandingan Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network Dengan Arsitektur ResNet18 dan ResNet50," *CSRID J.*, vol. 16, no. 1, p. 76, 2024, [Online]. Available: <https://www.doi.org/10.22303/csr.id.1.1.2022.01-10>
- [7] L. Trihardianingsih, A. Sunyoto, and T. Hidayat, "Classification of Tea Leaf Diseases Based on ResNet-50 and Inception V3," *Sinkron*, vol. 8, no. 3, pp. 1564–1573, 2023, doi: 10.33395/sinkron.v8i3.12604.
- [8] A. M. Tama and R. C. N. Santi, "Klasifikasi Jenis Tanaman Hias Menggunakan Metode Convolutional Neural Network (CNN)," *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, pp. 764–770, 2023, doi: 10.31539/intecom.v6i2.7002.
- [9] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [10] Y. Arti and A. M. Arymurthy, "Face Spoofing Detection using Inception-v3 on RGB Modal and Depth Modal," *J. Ilmu Komput. dan Inf.*, vol. 16, no. 1, pp. 47–57, 2023, doi: 10.21609/jiki.v16i1.1100.
- [11] A. Andrew and H. Santoso, "Compare VGG19, ResNet50, Inception-V3 for Review Food Rating," *Sinkron*, vol. 7, no. 2, pp. 845–494, 2022, doi: 10.33395/sinkron.v7i2.11383.