

Implementasi Algoritma *Convolutional Neural Network* dalam Menentukan Kelayakan Kayu

Rafino Ramdhanir Prasetyo Putra ¹, Muhammad Fachrie ^{2*}

^{1,2*} Program Studi Informatika, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Kabupaten Sleman, Provinsi Daerah Istimewa Yogyakarta, Indonesia.

Corresponding Email: finoraf01@gmail.com ¹

Histori Artikel:

Dikirim 1 Desember 2024; *Diterima dalam bentuk revisi* 10 Desember 2024; *Diterima* 1 Januari 2025; *Diterbitkan* 10 Januari 2025. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Kelayakan kayu merupakan faktor dengan nilai urgensi terpenting dalam dunia industri meubel atau furniture. Namun saat ini masih banyak produsen yang mengesampingkan kelayakan kayu sehingga dapat mempengaruhi hasil produksi dan harga jual. Dengan berkembangnya teknologi seperti pengolahan citra digital, proses pemilihan kayu yang layak dapat dilakukan tanpa memerlukan visual manusia. Penelitian ini mengusulkan untuk mengklasifikasikan kelayakan kayu berdasarkan citra digital kelayakan kayu menggunakan metode Deep Learning. Jaringan Syaraf Konvolusi (CNN) yang merupakan salah satu jenis dari algoritma Deep Learning diusulkan sebagai metode untuk melakukan analisis citra kelayakan kayu. Dataset citra kelayakan kayu didapatkan melalui observasi yang dilakukan peneliti di CV Kanindotama. Dataset yang digunakan pada penelitian ini berjumlah 105 citra kayu yang dibagi menjadi 83 data latih dan 22 data uji. Model yang dibangun menggunakan arsitektur ResNet50V2 mendapat akurasi paling besar hanya 69,51% untuk data latih dan 62,5% untuk data uji. Sedangkan model yang dibangun menggunakan arsitektur MobileNetV2 mendapatkan akurasi hingga 98,29% untuk data latih dan 100% untuk data uji. Hal tersebut membuktikan arsitektur MobileNetV2 lebih baik dibandingkan dengan ResNet50V2. Selain itu dapat dikatakan bahwa algoritma CNN dapat digunakan untuk melakukan analisis kelayakan kayu dengan baik.

Kata Kunci: Klasifikasi; Citra; Kayu; CNN; MobileNetV2.

Abstract

Wood eligibility is the most important factor in the furniture industry. However, currently there are still many producers who ignore the feasibility of wood so that it can affect production results and selling prices. With the development of technology such as digital image processing, the process of selecting feasible wood can be done without the need for human visuals. This research proposes to classify wood eligibility based on digital images of wood eligibility using the Deep Learning method. Convolutional Neural Network (CNN) which is one type of Deep Learning algorithm is proposed as a method to analyze wood worthiness images. The dataset of wood worthiness images was obtained through observations made by researchers at CV Kanindotama. The dataset used in this study amounted to 105 wood images divided into 83 training data and 22 test data. The model built using the ResNet50V2 architecture gets the greatest accuracy of only 69.51% for training data and 62.5% for test data. While the model built using the MobileNetV2 architecture gets an accuracy of up to 98.29% for training data and 100% for test data. This proves that the MobileNetV2 architecture is better than ResNet50V2. In addition, it can be said that the CNN algorithm can be used to analyze the feasibility of wood well.


Keyword: Classify; Digital Image; Wood; CNN; MobileNetV2.

1. Pendahuluan

Kayu merupakan bagian batang atau cabang tumbuhan yang mengalami pengerasan melalui proses lignifikasi alami. Kayu dimanfaatkan secara luas sebagai bahan bakar, material konstruksi, dekorasi rumah, dan berbagai kebutuhan lainnya. Sifat kayu yang tahan lama, kuat, dan tidak korosif menjadikannya material yang esensial dalam kehidupan manusia (Azwar Tsar Siregar, 2022). Indonesia adalah salah satu negara utama penghasil produk berbasis kayu, sehingga material tersebut memiliki peran signifikan dalam industri meubel atau *furniture* (Ridho *et al.*, 2024; Waliyansyah & Fitriyah, 2019). Dalam proses produksi meubel, pemilihan kayu berkualitas menjadi faktor yang sangat penting (Novyanto *et al.*, 2022). Sayangnya, masih banyak produsen yang mengabaikan kelayakan kayu, yang dapat berdampak pada penurunan kualitas hasil produksi serta memengaruhi harga jual (Akhyar *et al.*, 2022). Produk berkualitas tinggi secara langsung meningkatkan kepuasan pelanggan, yang pada akhirnya mendorong penjualan dan keuntungan perusahaan (Abdurrahman *et al.*, 2023). Keterbatasan manusia dalam mengidentifikasi kelayakan kayu secara visual dapat memengaruhi hasil yang diharapkan. Dengan kemajuan teknologi, seperti *digital image processing*, klasifikasi kelayakan kayu kini dapat dilakukan tanpa bergantung pada pengamatan manusia (Neneng *et al.*, 2020). Teknologi yang banyak digunakan untuk klasifikasi *digital image* adalah *Convolutional Neural Network* (CNN) (Sri Rahmadhani & Lysbetti Marpaung, 2023). Misalnya, penelitian oleh Azmi *et al.* (2023) memanfaatkan algoritma CNN untuk klasifikasi batik tanah liat Sumatera Barat, menghasilkan akurasi sebesar 98,75% pada data latih dan 62,5% pada data uji. Penelitian lain oleh Fathanah Mustamin *et al.* (2021) menunjukkan bahwa CNN dapat digunakan untuk klasifikasi kualitas kayu kelapa dengan akurasi hingga 85,89%. Hendriyana & Hilman Maulana (2020) juga menerapkan algoritma CNN dalam identifikasi jenis kayu, yang mencapai akurasi 98% pada data pelatihan dan 93,3% pada data pengujian. Selain algoritma CNN, metode lain seperti *K-Nearest Neighbors* (KNN) juga sering digunakan untuk klasifikasi *digital image*. Contohnya, penelitian oleh Akbar Anugrah Illahi & Tri Handoko (2023) menggunakan algoritma KNN untuk klasifikasi jenis buah kelengkeng berdasarkan warna, dengan akurasi rata-rata 89,6% pada data latih dan uji. Algoritma *Naive Bayes* juga digunakan, seperti yang ditunjukkan oleh Afriansyah *et al.* (2024), dalam klasifikasi buah pisang raja berbasis fitur warna, dengan akurasi rata-rata 86,6%. Penelitian ini menggunakan algoritma *Convolutional Neural Network* (CNN) untuk klasifikasi kelayakan kayu. Tujuan utamanya adalah menghasilkan klasifikasi kelayakan kayu secara akurat berdasarkan analisis data citra.

2. Metode Penelitian

Penelitian ini memanfaatkan Tensorflow Python dan menggunakan *Google Collaboratory* sebagai tools dan editor. Penelitian ini diawali dengan pengambilan data, persiapan data, pembuatan model dan evaluasi. Tahapan pada penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengambilan Data


Data dikumpulkan menggunakan perangkat *handphone* tipe Realme 5 dengan resolusi kamera 12 MP. Gambar kayu diambil dalam kondisi pencahayaan alami pada pukul 08.00–12.00 untuk meminimalkan efek bayangan. Setiap objek kayu difoto dari jarak 30 cm dengan sudut tegak lurus terhadap permukaan kayu. Penelitian ini menggunakan data primer yang diperoleh melalui perangkat *handphone*. Kayu yang digunakan sebagai objek penelitian terdiri dari kayu mahoni dan mindi, yang diambil dari Kabupaten Jepara. Jumlah data citra yang terkumpul sebanyak 105 gambar, terdiri dari 70 gambar kayu layak dan 35 gambar kayu tidak layak.



Gambar 2. (a) Citra Kayu Layak; (b) Citra Kayu Tidak Layak

2.2 Persiapan Data


Setelah pengambilan gambar, data citra diolah melalui proses *cropping* untuk memusatkan fokus pada permukaan kayu. Selanjutnya, gambar diubah ukurannya (*resized*) menjadi dimensi 224x224 piksel agar sesuai dengan format input model *Convolutional Neural Network* (CNN). Untuk meningkatkan variasi data citra dan kinerja model klasifikasi, dilakukan augmentasi data dengan teknik seperti rotasi, flipping, dan zooming (DLY *et al.*, 2023). Dataset kemudian dibagi dengan rasio 4:1 untuk data latih dan data uji. Hasil dari proses augmentasi dapat dilihat pada gambar 3.



Gambar 3. Citra Hasil Augmentasi


2.3 Pembuatan Model

Model yang dibangun pada penelitian ini dibuat dengan memanfaatkan metode *Deep Learning* yaitu Jaringan Syaraf Konvolusi. Model yang diusulkan memanfaatkan pretrained arsitektur *MobileNetV2* dan *ResNet50V2*. *MobileNetV2* yang diperkenalkan pada tahun 2018 tetap menggunakan *depthwise* dan *pointwise convolution* seperti pendahulunya. Namun, pada versi 2, *linear bottleneck* dan *shortcut connections* menjadi fitur baru yang meningkatkan efisiensi dan kinerja model (Nada Nafisa *et al.*, 2023). Arsitektur *MobileNetV2* dapat dilihat pada gambar 4.




Gambar 4. Arsitektur *MobileNetV2* (Nada Nafisa *et al.*, 2023)

ResNet50V2 merupakan arsitektur konvolusi kontemporer yang mengatasi Vanishing Gradient yang menghilang menggunakan blok residual. Setiap blok residual dibentuk oleh satu atau lebih lapisan (layer) (Nugraha *et al.*, 2022), (Agil Izzulhaq, 2024). Gambar arsitektur *ResNet50V2* seperti pada gambar 5.



Gambar 5. Arsitektur *ResNet50V2* (Agil Izzulhaq, 2024)

Arsitektur *MobileNetV2* cukup ringan sehingga dapat melakukan pembelajaran data lebih cepat (Indraswari *et al.*, 2022). Sedangkan Arsitektur *ResNet50V2* merupakan model yang memiliki fungsi untuk mengatasi Vanishing Gradient yang disebabkan oleh banyaknya layer sehingga memerlukan komputasi yang lebih lama (Nugraha *et al.*, 2022). Untuk model yang diusulkan pada penelitian ini dapat dilihat pada gambar 6.



Gambar 6. Model yang diusulkan

Seperti yang terlihat pada Gambar 6 model CNN dalam penelitian ini dirancang dengan pendekatan transfer learning menggunakan *MobileNetV2* atau *ResNet50V2* sebagai *feature extractor*. Model ini menerima input gambar berukuran (224, 224, 3) dan memanfaatkan bobot awal yang dilatih pada dataset *ImageNet*. Lapisan tambahan meliputi *flatten*, dua lapisan *dense* dengan 128 dan 64 *neuron* menggunakan fungsi aktivasi *ReLU*, serta *dropout* sebesar 20% dan 50% untuk mengurangi resiko *overfitting*. Lapisan output terdiri dari satu neuron dengan fungsi aktivasi *sigmoid* untuk menghasilkan probabilitas klasifikasi biner kayu layak atau tidak layak.

2.4 Evaluasi

Evaluasi yang dilakukan pada penelitian ini adalah dengan melihat tingkat akurasi pada setiap eksperimen yang dilakukan dengan menggunakan fungsi seperti pada Gambar 7.

Actual Class \ Predicted Class	P	N
P	TP $\lambda_{pp}m_p$	FN $(1-\lambda_{pp})m_p$
N	FP $(1-\lambda_{nn})m_n$	TN $\lambda_{nn}m_n$

Gambar 7. *Confusion Matrix* (Purnama *et al.*, 2024)

Untuk menghitung akurasi pada hasil *Confusion Matrix* menggunakan rumus seperti pada persamaan (1).

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+FN}$$

Uji coba dilakukan dengan mengubah *learning rate* dengan penurunan dari 0,1 hingga 0,001. Uji coba yang dilakukan dapat dilihat pada tabel 1.

Tabel 1. Parameter Eksperimen

Arsitektur	Optimasi	Learning Rate	Epoch
MobileNetV2	Adam	0,1	50
MobileNetV2	Adam	0,01	50
MobileNetV2	Adam	0,001	50
ResNet50V2	Adam	0,1	50
ResNet50V2	Adam	0,01	50
ResNet50V2	Adam	0,001	50

3. Hasil dan Pembahasan


3.1 Hasil

Berdasarkan hasil uji coba yang telah dilakukan, didapatkan hasil akurasi dari arsitektur MobileNetV2 dan ResNet50V2 dengan parameter seperti pada tabel 1. Hasil uji coba yang telah dilakukan dapat dilihat pada tabel 2.


Tabel 2. Hasil Eksperimen

Percobaan Ke-	MobileNetV2		ResNet50V2	
	Akurasi Data Latih	Akurasi Data Uji	Akurasi Data Latih	Akurasi Data Uji
1	68,54%	87,5%	65,29%	62,5%
2	82,03%	87,5%	69,51%	62,5%
3	98,29%	100%	68,33%	62,5%
Rata-Rata	82,95%	91,6%	67,71%	62,5%

Dari tabel 2, dapat diketahui bahwa hasil uji coba ke-3 mendapatkan hasil yang paling optimal dibandingkan dengan lainnya. Hasil uji coba ke-3 dengan arsitektur MobileNetV2 mendapatkan akurasi sebesar 98,29% untuk data latih dan 100% untuk data uji. Sementara itu untuk hasil uji coba terbaik untuk arsitektur ResNet50V2 ada pada percobaan ke-2 dengan akurasi sebesar 69,51% untuk data latih dan 62,5% untuk data uji. Dengan hasil tersebut uji coba ke-3 menggunakan arsitektur MobileNetV2 dengan optimasi Adam, learning rate 0,001, dan 50 Epoch memberikan hasil yang optimal dari keseluruhan uji coba yang dilakukan. Untuk grafik akurasi pada setiap arsitektur dapat dilihat pada gambar 8-9.



Gambar 8. Grafik Akurasi saat Training *MobileNetV2*



Gambar 9. Grafik Akurasi saat Training ResNet50V2

Dari grafik diatas dapat dilihat bahwa arsitektur ResNet50V2 memiliki akurasi yang tidak stabil pada setiap stepnya. Akurasi yang didapatkan hingga step terakhir hanya berada di sekitar 60% yang menandakan proses pembelajaran kurang optimal. Sebaliknya pada arsitektur MobileNetV2 grafik akurasi lebih stabil pada setiap stepnya. Akurasi yang didapatkan bisa mencapai 100% namun menurun pada akhir stepnya.

3.2 Pembahasan

Hasil penelitian menunjukkan bahwa algoritma *Convolutional Neural Network* (CNN) dapat digunakan secara efektif untuk klasifikasi kelayakan kayu berdasarkan data citra digital. Arsitektur MobileNetV2 menghasilkan performa terbaik dengan akurasi 98,29% pada data latih dan 100% pada data uji. Hal ini sesuai dengan penelitian sebelumnya, yang menunjukkan bahwa MobileNetV2 memberikan hasil optimal untuk tugas klasifikasi citra, seperti pendeteksian penyakit pada citra fundus (Indraswari *et al.*, 2022) dan klasifikasi tumor otak berbasis citra (Nada Nafisa *et al.*, 2023). ResNet50V2 memiliki rata-rata akurasi 67,71% untuk data latih dan 62,5% untuk data uji. Penurunan performa ini dapat disebabkan oleh kebutuhan komputasi yang lebih tinggi dan potensi *overfitting* pada dataset kecil, seperti yang juga dilaporkan dalam penelitian mengenai pengenalan objek menggunakan arsitektur serupa (Nugraha *et al.*, 2022; Agil Izzulhaq, 2024).

Proses augmentasi data, termasuk rotasi, *flipping*, dan *zooming*, membantu meningkatkan variasi data yang tersedia untuk pelatihan model. Teknik augmentasi semacam ini telah terbukti meningkatkan performa model dalam penelitian lain, seperti klasifikasi batik tanah liat (Azmi *et al.*, 2023) dan klasifikasi citra daging sapi dan babi (DLY *et al.*, 2023). Selain itu, pengolahan data dengan *cropping* dan *resizing* memastikan kesesuaian dimensi citra dengan input model, yang mempermudah proses pelatihan. Pengaturan parameter *learning rate* juga memberikan dampak signifikan terhadap hasil model. Nilai *learning rate* sebesar 0,001 pada MobileNetV2 memberikan akurasi yang lebih stabil dibandingkan nilai lainnya. Hal ini mendukung penelitian lain yang menunjukkan bahwa penyesuaian *learning rate* sangat penting untuk mengoptimalkan pelatihan model pada tugas klasifikasi (Purnama *et al.*, 2024). Selain CNN, algoritma lain seperti *K-Nearest Neighbors* (KNN) dan *Naive Bayes* memiliki aplikasi yang relevan untuk tugas klasifikasi citra. Misalnya, KNN berhasil digunakan untuk klasifikasi jenis buah kelengkeng berdasarkan warna citra (Akbar Anugrah Illahi & Tri Handoko, 2023; Ridho *et al.*, 2024), sementara *Naive Bayes* digunakan untuk klasifikasi buah pisang raja berdasarkan fitur warna (Afriansyah *et al.*, 2024). Hasil menunjukkan bahwa CNN, khususnya MobileNetV2, lebih unggul dalam mengolah data citra dengan pola yang kompleks. Penelitian ini menunjukkan bahwa algoritma CNN mampu melakukan klasifikasi kelayakan kayu dengan tingkat akurasi yang tinggi, mendukung aplikasinya dalam berbagai industri terkait (Akhyar *et al.*, 2022). Namun, keterbatasan pada jumlah dataset memengaruhi generalisasi model. Peningkatan jumlah dan variasi data di masa depan sangat disarankan untuk memperoleh hasil yang lebih akurat.

4. Kesimpulan dan Saran

Dari Eksperimen yang telah dilakukan, metode Jaringan Syaraf Konvolusi dapat melakukan analisis klasifikasi kelayakan kayu. Model terbaik didapatkan dengan menggunakan pretrained model MobileNetV2 dengan rata-rata akurasi 82,95% untuk data latih dan 91,6% untuk data uji. Model yang paling optimal diperoleh menggunakan MobileNetV2 pada eksperimen ke-3 yang mendapatkan akurasi 98,29% untuk data latih dan 100% untuk data uji. Selain itu hasil juga menunjukkan bahwa besarnya learning rate sangat memengaruhi akurasi yang didapatkan model. Semakin kecil *learning rate* yang digunakan maka akurasi juga semakin baik. Saran untuk penelitian selanjutnya yaitu dengan menambah jumlah dataset yang digunakan sehingga dapat melihat hubungan tentang banyaknya variasi data yang digunakan dengan hasil akurasi yang didapat. Selain itu algoritma yang digunakan pada penelitian selanjutnya lebih bervariasi seperti KNN, Naive Bayes, maupun algoritma klasifikasi lainnya. Hal tersebut dimaksudkan agar dapat lebih membuktikan apakah algoritma CNN lebih baik dari algoritma lain.

5. Daftar Pustaka

- Abdurrahman, M., Rizqi, A. W., & Jufriyanto, M. (2023). Pengendalian Kualitas Kayu Kering Pada Mesin Kiln Dryer Untuk Mengurangi Produk Cacat Dengan Metode Seven Tools Dan Failure Mode Effect Analysis. *Jurnal Serambi Engineering*, 8(4).
- Afriansyah, M., Saputra, J., Ardhana, V. Y. P., & Sa'adati, Y. (2024). ALGORITMA NAIVE BAYES YANG EFISIEN UNTUK KLASIFIKASI BUAH PISANG RAJA BERDASARKAN FITUR WARNA. *Journal of Information Systems Management and Digital Business*, 1(2), 236-248. <https://doi.org/10.59407/jismdb.v1i2.438>.
- AKHYAR, F., NOVAMIZANTI, L., & RIAN TIARNI, T. (2022). Sistem Inspeksi Cacat pada Permukaan Kayu menggunakan Model Deteksi Obyek YOLOv5. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(4), 990. <https://doi.org/10.26760/elkomika.v10i4.990>.
- Azmi, K., Defit, S., & Sumijan, S. (2023). Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat sumatera barat. *Jurnal Unitek*, 16(1), 28-40. <https://doi.org/10.52072/unitek.v16i1.504>.
- DLY, I. A., Jasril, J., Sanjaya, S., Handayani, L., & Yanto, F. (2023). Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data. *Journal of Information System Research (JOSH)*, 4(4), 1176-1185. <https://doi.org/10.47065/josh.v4i4.3702>.
- Harahap, F. A. A., Nafisa, A. N., Purba, E. N. D. B., & Putri, N. A. (2023). Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma. *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTika)*, 5(1), 53-61. <https://doi.org/10.29303/jtika.v5i1.234>.
- Hendriyana, H., & Maulana, Y. H. (2020). Identification of types of wood using convolutional neural network with MobileNet architecture. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(1), 70-76.

- Illahi, M. A. A., & Handoko, W. T. (2023). Klasifikasi Jenis Buah Kelengkeng Dengan Metode K-Nearest Neighbor (KNN) Berdasarkan Citra Warna Buah. *Kesatria: Jurnal Penerapan Sistem Informasi (Komputer dan Manajemen)*, 4(3), 566-573. <https://doi.org/10.30645/kesatria.v4i3.205>.
- Indraswari, R., Herulambang, W., & Rokhana, R. (2022). Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN). *Techno. com*, 21(2).
- Izzulhaq, M. A., & Alamsyah, A. (2024). Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet50V2 Untuk Mengidentifikasi Penyakit Pneumonia. *Indonesian Journal of Mathematics and Natural Sciences*, 47(1), 12-22. <https://doi.org/10.15294/p532ny06>.
- Mustamin, N. F., Sari, Y., & Khatimi, H. (2021). Klasifikasi kualitas kayu kelapa menggunakan arsitektur CNN. *KLIK-KUMPULAN JURNAL ILMU KOMPUTER*, 8(1), 49-59.
- Neneng, N., Putri, N. U., & Susanto, E. R. (2021). Klasifikasi Jenis Kayu Menggunakan Support Vector Machine Berdasarkan Ciri Tekstur Local Binary Pattern. *Cybernetics*, 4(02), 93-100.
- Novyanto, F., & Nurraharjo, E. (2022). Penentuan Jenis Kayu Untuk Bahan Meubel Dengan Metode Saw. *Jurnal Informatika dan Rekayasa Elektronik*, 5(2), 191-200. <https://doi.org/10.36595/jire.v5i2.683>.
- Nugraha, P., Komarudin, A., & Ramadhan, E. (2022). Deteksi Objek Dan Jenis Burung Menggunakan Convolutional Neural Network Dengan Arsitektur Inception Resnet-V2. *INFOTECH journal*, 8(2), 43-51. <https://doi.org/10.31949/infotech.v8i2.2889>.
- Purnama, B., Winarto, E. A., Shairupudin, S., & Wijaya, I. S. Deteksi Malware Ransomware Menggunakan Deep Neural Network. *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 10(1), 8-12.
- Rahmadhani, U. S., & Marpaung, N. L. (2023). Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN. *Jurnal Informatika: Jurnal Pengembangan IT*, 8(2), 169-173. <https://doi.org/10.30591/jpit.v8i2.5229>.
- Ridho, A., Setiawan, A. F., & Vendyansyah, N. (2024). Klasifikasi kualitas kayu dengan metode k-nearest neighbors (KNN) berbasis website. *Jurnal Mahasiswa Teknik Informatika*, 8(5), 8609–8617.
- Tsar Siregar, M. A. (2022). *IDENTIFIKASI CACAT PADA KAYU MENGGUNAKAN FITUR GLCM DENGAN METODE SVM* (Doctoral dissertation, Universitas Multi Data Palembang).
- Waliyansyah, R. R., & Fitriyah, C. (2019). Perbandingan Akurasi Klasifikasi Citra Kayu Jati Menggunakan Metode Naive Bayes dan k-Nearest Neighbor (k-NN). *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 5(2), 157-163. <https://doi.org/10.26418/jp.v5i2.32473>.