

KLASIFIKASI JENIS KAYU BERDASARKAN CITRA SERAT KAYU MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

Muhammad Rifaldi Dwimahendra^{*1)}, Syahrullah²⁾, Yuri Yudhaswana Joeffie³⁾, Dwi Shinta Angreni⁴⁾, Ryfial Azhar⁵⁾, Deny Wiria Nugraha⁶⁾, Nouval Trezandy Lapatta⁷⁾, Abdul Mahatir Najar⁸⁾

1. Teknik Informatika, Fakultas Teknik, Universitas Tadulako, Indonesia
2. Sistem Informasi, Fakultas Teknik, Universitas Tadulako, Indonesia
3. Teknik Informatika, Fakultas Teknik, Universitas Tadulako, Indonesia
4. Sistem Informasi, Fakultas Teknik, Universitas Tadulako, Indonesia
5. Teknik Informatika, Fakultas Teknik, Universitas Tadulako, Indonesia
6. Teknik Informatika, Fakultas Teknik, Universitas Tadulako, Indonesia
7. Teknik Informatika, Fakultas Teknik, Universitas Tadulako, Indonesia
8. Matematika, Fakultas MIPA, Universitas Tadulako, Indonesia

Article Info

Kata Kunci: Citra Serat Kayu; *Convolutional Neural Network*; Jenis kayu; Industri Mebel; Klasifikasi

Keywords: *Classification; Convolutional Neural Network; Furniture Industry; Wood Fiber Image; Wood Types*

Article history:

Received 15 Oktober 2024
Revised 17 November 2024
Accepted 1 Maret 2025
Available online 1 Maret 2025

DOI :

<https://doi.org/10.29100/jipi.v10i1.5726>

* Corresponding author.

Corresponding Author

E-mail address:

rifalddwimahendra@gmail.com

ABSTRAK

Kayu merupakan sumber daya alam yang sangat penting bagi industri mebel atau furnitur. Pemilihan jenis kayu yang tepat sangat krusial dalam industri mebel untuk menentukan kualitas hasil produksi. Pemilihan kayu secara manual memiliki risiko kesalahan yang dapat berdampak negatif pada kualitas akhir produk mebel. Oleh karena itu, diperlukan penerapan teknologi untuk meminimalkan kesalahan pemilihan jenis kayu dan meningkatkan efisiensi proses produksi. Penelitian ini bertujuan membangun model klasifikasi jenis kayu (nantu, palapi, dan uru) berbasis *Convolutional Neural Network* (CNN) menggunakan citra serat kayu. Dataset terdiri dari 1.584 citra yang dibagi menjadi 80% data pelatihan dan 20% data pengujian. Arsitektur model CNN terdiri dari 4 lapisan konvolusi, 4 lapisan pooling, dan 2 lapisan fully-connected. Hasil pelatihan mencapai akurasi 97,06%, sedangkan hasil pengujian dan evaluasi menggunakan matriks kebingungan mencapai akurasi 95,56%. Penelitian ini membuktikan bahwa CNN dapat digunakan secara efektif untuk klasifikasi jenis kayu dengan tingkat akurasi yang tinggi, sehingga dapat membantu meningkatkan efisiensi proses produksi mebel.

ABSTRACT

Wood is a highly important natural resource for the furniture industry. The selection of the right type of wood is crucial in the furniture industry to determine the quality of the final products. Manual selection of wood has the risk of errors that can negatively impact the final quality of furniture products. Therefore, the application of technology is necessary to minimize errors in the selection of wood types and improve the efficiency of the production process. This study aims to build a *Convolutional Neural Network* (CNN) based classification model for wood types (nantu, palapi, and uru) using wood fiber images. The dataset consists of 1,584 images that are divided into 80% training data and 20% testing data. The CNN model architecture consists of 4 convolutional layers, 4 pooling layers, and 2 fully-connected layers. The training results achieved an accuracy of 97.06%, while the testing and evaluation results using the confusion matrix reached an accuracy of 95.56%. This research proves that CNN can be used effectively for wood type classification with a high accuracy level, thus helping to improve the efficiency of the furniture production process.

I. PENDAHULUAN

KAYU merupakan pilihan utama dalam konstruksi dan furnitur. Selain baja ringan dan beton, kayu masih digunakan sebagai bahan baku utama dalam pembangunan rumah [1]. Dalam industri furnitur, kayu memiliki peran dominan dalam produksi perabot rumah seperti lemari, pintu, jendela, dan kursi. Setiap kayu memiliki kelebihan dan kekurangan yang merupakan karakteristik yang menentukan kegunaannya[2].

Jenis kayu palapi (*Heritiera spp*) dan kayu nantu (*Palaquium obtusilofium*) adalah jenis-jenis kayu yang pohonnya dapat tumbuh secara alami di Sulawesi Tengah dan telah dibudidayakan dalam hutan rakyat Kabupaten Parigi Moutong dan Donggala. Kedua jenis kayu ini juga umum digunakan sebagai bahan dasar produksi mebel [3]. Mebel Alvian adalah salah satu produsen mebel di Kota Palu yang menggunakan kedua jenis kayu tersebut, selain itu Mebel Alvian juga menggunakan jenis kayu uru (cempaka) yang juga merupakan kayu lokal Sulawesi Tengah.

Pemilihan jenis kayu yang tepat sangat penting dalam menjaga kualitas hasil produksi, karena setiap jenis kayu memiliki kelebihan dan kekurangan yang berbeda yang menentukan fungsinya [2]. Saat ini, pemilihan jenis kayu umumnya masih dilakukan secara visual oleh manusia. Kemampuan untuk mengklasifikasikan jenis kayu memerlukan proses pelatihan yang berulang-ulang dan membutuhkan waktu yang lama. Keterbatasan kemampuan manusia dalam mengklasifikasikan jenis kayu secara visual yang belum terampil terkadang dapat mempengaruhi hasil pemilihan jenis kayu [4]. Kesalahan pemilihan jenis kayu dapat berdampak pada harga, tingkat kesulitan pengerjaan serta berdampak negatif pada hasil produksi [5].

Klasifikasi merupakan proses menilai dan mengelompokkan objek data ke dalam kategori atau kelas tertentu dari sejumlah kelas yang telah ditetapkan sebelumnya [6]. Klasifikasi merupakan salah satu teknik yang digunakan untuk mengidentifikasi pola-pola yang membedakan antara kelas data yang berbeda, dengan tujuan menentukan kategori objek yang baru berdasarkan perilaku dan atribut dari kelompok yang telah ditentukan sebelumnya. Teknik ini juga dapat digunakan untuk menghasilkan sejumlah aturan yang dapat digunakan dalam mengklasifikasikan data baru. Beberapa algoritma yang umum digunakan dalam melakukan klasifikasi antara lain *K-Nearest Neighbor* (KNN), ANN, *Naive Bayes*, dan *Decision Tree*. [7].

Artificial Intelligence (AI) atau kecerdasan buatan merupakan suatu metode yang memungkinkan komputer untuk memiliki kemampuan berpikir dan bertindak secara mirip dengan manusia. Dalam perkembangannya, AI telah banyak digunakan dan diaplikasikan di berbagai aspek kehidupan sehari-hari. Salah satu subdisiplin dalam domain AI adalah *Machine Learning* (ML). Teknik ML memungkinkan komputer untuk mengamati data yang ada, membangun sebuah model berdasarkan data tersebut, dan menggunakan model tersebut untuk memecahkan masalah tertentu. Dengan adanya ML, komputer dapat secara otomatis meningkatkan kinerjanya seiring dengan pengalaman dan data yang diperoleh [8].

Artificial Neural Networks (ANN) mengadaptasi struktur otak manusia dengan tujuan meniru respon otak dalam melakukan. Mirip dengan susunan otak manusia, ANN terdiri dari kumpulan neuron yang saling terhubung dan dapat mengirimkan sinyal aktivasi [9]. Dengan menggunakan arsitektur yang kompleks, ANN mampu memodelkan fungsi-fungsi yang sangat kompleks dan non-linear. ANN harus dilatih secara bertahap dengan memproses data pelatihan dan mengatur parameter model berdasarkan berbagai metode pelatihan hingga keluaran model mencapai tujuan yang diinginkan. Dengan menggunakan model ini, ANN memiliki efektivitas yang tinggi dalam berbagai aplikasi seperti estimasi, klasifikasi, dan pengenalan [10].

Convolutional Neural Network (CNN) merupakan jenis ANN yang digunakan untuk melakukan pemrosesan dan ekstraksi informasi dari kumpulan data, salah satu jenis data yang umum digunakan dalam CNN adalah data Citra. CNN bekerja dengan mengkonversi citra digital menjadi matriks dua dimensi, dengan setiap pikselnya memiliki nilai tersendiri. Proses ini memungkinkan CNN untuk mendapatkan fitur-fitur dari citra serat kayu dengan baik. Selanjutnya, melalui lapisan konvolusi, CNN melakukan operasi konvolusi berulang-ulang untuk mengekstrak fitur-fitur penting dari citra. Kemudian lapisan pooling memperkecil ukuran matriks, menyederhanakan representasi fitur tanpa menghilangkan informasi penting dari data. Setelah melalui lapisan *flatten* yang mengubah matriks menjadi vektor satu dimensi, fitur-fitur yang telah diekstraksi dihubungkan melalui lapisan *fully connected* untuk mendapatkan hasil klasifikasi. [11]. CNN memiliki beberapa kelebihan seperti penggunaan fitur pembagian bobot yang mengurangi jumlah parameter dalam jaringan pelatihan yang membantu menghindari generalisasi yang berlebihan yang dapat menyebabkan *overfitting* dan mempelajari dan memproses lapisan ekstraksi fitur dan klasifikasi secara bersamaan yang menghasilkan keluaran model yang terorganisir dengan sangat bergantung pada fitur-fitur yang diekstraksi [12]. Pada kasus tertentu CNN memiliki kinerja yang lebih baik dalam klasifikasi citra dibandingkan algoritma klasifikasi lain seperti *Support Vector Machine* (SVM) dan *K-Nearest Neighbour* (KNN) [13].

Terdapat beberapa contoh penggunaan CNN untuk melakukan klasifikasi citra, penelitian yang dilakukan oleh [11] menggunakan CNN untuk membuat model klasifikasi jenis jamur berdasarkan citra dan diimplementasikan kedalam aplikasi berbasis mobile. penelitian ini menggunakan data citra 5 jenis jamur berjumlah 3015 citra yang didapatkan dari situs *Kaggle* dan diambil secara langsung di lokasi budidaya jamur tiram, data dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Kemudian model dilatih dengan data yang telah dibagi menggunakan arsitektur *LeNet-5*, arsitektur ini digunakan karena cukup sederhana namun dapat menghasilkan model dengan kinerja yang cukup baik. Penelitian ini yang menghasilkan akurasi hasil pelatihan model sebesar 96 %, pengujian model mendapatkan hasil akurasi sebesar 84%.

Penelitian lain yang dilakukan oleh [14] yang bertujuan mengatasi kendala dalam klasifikasi jenis buah pisang menggunakan CNN untuk melakukan klasifikasi pada 3 jenis buah pisang, yaitu pisang jantan, pisang kepok, dan pisang muli. Data yang digunakan berjumlah 1000 data citra pada masing-masing kelas dengan perbandingan 80% untuk training dan 20% untuk testing. Pada penelitian ini model menggunakan arsitektur VGG-16, arsitektur ini dipilih karena memiliki tingkat ketelitian yang cukup tinggi dan waktu pelatihan yang relatif singkat, dengan learning rate 0.001, batch size 64 dan dilatih sebanyak 50 epoch/iterasi dengan optimizer adam. Model yang dihasilkan memiliki nilai akurasi sebesar 78%, presisi sebesar 81% dan recall sebesar 78%.

Dalam kasus klasifikasi kayu, penelitian yang dilakukan oleh [1] menggunakan metode CNN untuk membangun sebuah model klasifikasi 4 jenis kayu. Data citra kayu yang digunakan dalam penelitian ini diambil secara alami tanpa pengaturan pencahayaan khusus. Data citra kayu kemudian dibagi menjadi tiga kelompok, yaitu data pelatihan, data validasi, dan data pengujian. Dalam penelitian ini, peneliti menggunakan model yang mengadaptasi arsitektur VGG-16 yang merupakan model yang memiliki kedalaman dan tingkat akurasi yang cukup baik dan waktu pelatihan yang relatif singkat. Penyesuaian yang dilakukan meliputi penurunan jumlah *filter* pada lapisan konvolusi pertama hingga kedelapan menjadi 1/8 dari jumlah *filter* awalnya. Selain itu, jumlah *filter* pada lapisan konvolusi kesembilan dan kesepuluh juga diturunkan menjadi 1/3 dari jumlah *filter* awalnya. Pada proses pelatihan, model CNN dilatih selama 600 kali *epoch*/iterasi menggunakan 733 data latih dan 207 data validasi, kemudian dilakukan pengujian pada model yang telah dilatih menggunakan 100 data citra yang mewakili 4 jenis kayu. Hasil pengujian menghasilkan nilai rata-rata akurasi sebesar 95%.

Sebagai perbandingan, dapat dilihat pada penelitian yang dilakukan oleh [15] menggunakan *Learning Vector Quantization* (LVQ) untuk melakukan klasifikasi terhadap 3 jenis kayu berdasarkan ciri tekstur *Local Binary Pattern* (LBP) dari citra kayu. Data yang digunakan sebanyak 240 data citra yang dibagi menjadi 80% untuk data pelatihan dan 20% untuk data uji secara acak. Model dilatih dengan nilai *learning rate* sebesar 0,1 selama 100 kali *epoch*/iterasi. Hasil pengujian model didapatkan akurasi sebesar 68,33%.

Penelitian-penelitian tersebut membuktikan bahwa CNN dapat digunakan secara efektif untuk klasifikasi citra. Dibandingkan dengan metode lain seperti LVQ, CNN mampu menghasilkan kinerja yang lebih baik dalam klasifikasi jenis kayu. Hal ini menunjukkan bahwa CNN mampu mengekstrak fitur visual yang relevan secara efisien dan menghasilkan model klasifikasi dengan akurasi tinggi.

II. METODE PENELITIAN

Metode penelitian ini terdiri dari beberapa tahapan, dimulai dari pengumpulan data, *preprocessing* data, pembuatan arsitektur model, pelatihan model hingga pengujian dan evaluasi.

A. Pengumpulan data

Proses pengumpulan data merupakan langkah awal yang penting dalam keseluruhan penelitian, karena kualitas dataset akan menentukan keberhasilan tahapan-tahapan selanjutnya. Pengumpulan data secara langsung dari sumber yang relevan dilakukan untuk memastikan dataset yang digunakan representatif dan mencakup variasi yang cukup [15]. Pada penelitian ini, pengumpulan data dilakukan langsung dari Mebel Alvian yang berlokasi di kota palu, Provinsi Sulawesi Tengah. Pengambilan data menggunakan kamera *smartphone* dengan fitur *ultra macro*, jarak pengambilan citra sebesar 4 cm dengan sudut pengambilan gambar yang tegak lurus dengan objek. Pengambilan citra dilakukan dengan pengaturan cahaya yang disesuaikan untuk memastikan data citra yang diambil dapat memuat ciri serat kayu dengan baik. Contoh data serat kayu dapat dilihat pada Gambar 1.



Gambar 1. Data Citra Serat Kayu Nantu, Palapi dan Uru

B. Preprocessing data

Preprocessing adalah teknik yang umum digunakan dalam *deep learning*. Proses ini melakukan pemuatan (*loading*) dan beberapa penyesuaian pada data yang kemudian disimpan ke dalam objek yang memuat data yang telah disesuaikan. Data yang telah disesuaikan tersebut dapat digunakan secara berulang pada tahapan pelatihan dan pengujian model [16]. Tujuan utama *preprocessing* data adalah untuk mengoptimalkan informasi dari data, meningkatkan kualitas data agar dapat diproses dengan benar, serta mengurangi waktu pemrosesan data [15]. Tahapan *preprocessing* data dimulai dengan melakukan augmentasi untuk memperbanyak dan memperkaya variasi data. Data awal yang akan digunakan pada penelitian ini berjumlah 176 citra untuk setiap kelas, Selanjutnya, data tersebut di-augmentasi dengan cara *rotate* 90°, *flip* vertikal dan horizontal, teknik - teknik ini akan menghasilkan data citra serat kayu dengan orientasi yang lebih bervariasi. Proses augmentasi menghasilkan 528 data untuk setiap kelas. Rician jumlah data sebelum dan setelah augmentasi dapat dilihat pada Tabel I.

TABEL I
Jumlah Data Sebelum dan Setelah Augmentasi

Jenis Kayu	Sebelum	Pengujian
Nantu	176	528
Palapi	176	528
Uru	176	528
Total	528	1584


Setelah augmentasi selesai, data hasil proses augmentasi dibagi dengan perbandingan 80% untuk data pelatihan dan 20% untuk data pengujian. Selanjutnya, data pelatihan dibagi dengan perbandingan 75% untuk data latih dan 25% untuk data validasi. Detail pembagian data dapat dilihat pada Tabel II.

TABEL II
Jumlah Data Pelatihan, Validasi dan Pengujian

Jenis Kayu	Pelatihan	Validasi	Pengujian	Total
Nantu	317	106	105	528
Palapi	317	106	105	528
Uru	317	106	105	528
Total	951	318	315	1584

C. Arsitektur model

Dalam membangun arsitektur model terdapat beberapa parameter yang perlu diperhatikan, seperti jumlah lapisan konvolusional, ukuran filter, dan pooling yang dapat mempengaruhi kompleksitas fitur yang dipelajari oleh model. Selain itu, fungsi aktivasi dan jumlah neuron pada lapisan fully connected juga merupakan faktor-faktor yang penting dalam merancang arsitektur CNN yang menentukan efektifitas model klasifikasi yang akan dibangun [17]. Arsitektur CNN yang digunakan dalam penelitian ini terinspirasi dari arsitektur VGG-16 yang memiliki beberapa lapisan konvolusi dengan ukuran *filter* 3x3, dengan penggunaan lapisan *max pooling* setelah setiap blok konvolusi, dan peningkatan jumlah *filter* pada setiap blok konvolusi yang disesuaikan untuk mendapatkan model yang lebih sederhana, penyesuaian yang dilakukan yaitu pengurangan jumlah lapisan konvolusi menjadi 4 blok, pemilihan jumlah *filter* yang lebih kecil, serta penyederhanaan lapisan *fully connected* menjadi hanya 2 lapisan *fully connected* dengan jumlah *unit* yang kecil. Penyesuaian-penyesuaian ini dilakukan meningkatkan efisiensi komputasi dengan mengurangi kompleksitas model, dan meningkatkan kemampuan generalisasi dengan mencegah overfitting. Penyederhanaan ini dapat digunakan dalam kasus klasifikasi citra serat kayu dengan karakteristik data yang tidak terlalu kompleks. Visualisasi arsitektur model yang digunakan pada penelitian ini dapat dilihat pada Gambar 2.



Gambar. 2. Diagram Alur Model CNN

Fungsi aktivasi yang digunakan pada lapisan konvolusi dan *fully connected* dalam model ini yaitu fungsi aktivasi *ReLU (Rectified Linear Unit)*. Fungsi aktivasi ini sangat umum digunakan dalam model CNN. Keunggulan fungsi aktivasi *ReLU* dibandingkan dengan fungsi aktivasi lainnya, seperti *sigmoid* dan *tanh*, yaitu komputasi yang lebih efisien, mempercepat konvergensi selama pelatihan menggunakan metode *gradient descent stochastic*, dan meningkatkan kemampuan model dalam mempelajari representasi fitur yang bervariasi [1]. Pada layer output model digunakan fungsi aktivasi *softmax* yang merupakan salah satu bentuk *logistic regression* yang dapat digunakan dalam melakukan klasifikasi multi-kelas. fungsi aktivasi *softmax* mengubah output model menjadi distribusi probabilitas yang memungkinkan model untuk melakukan klasifikasi [18]. Detail model yang digunakan dapat dilihat pada Tabel III.

TABEL III
 DESAIN ARSITEKTUR MODEL

Layers	Type	Filter / Kernel	Activation Function	Batch Size	Output Shape			Parameters
					Rows	Columns	Channels	
Konvolusi 1	<i>Conv2D</i>	3×3	<i>ReLU</i>	<i>None</i>	253	253	32	896
Pooling 1	<i>MaxPooling2D</i>	-	-	<i>None</i>	126	126	32	0
Konvolusi 2	<i>Conv2D</i>	3×3	<i>ReLU</i>	<i>None</i>	124	124	64	18496
Pooling 2	<i>MaxPooling2D</i>	-	-	<i>None</i>	62	62	64	0
Konvolusi 3	<i>Conv2D</i>	3×3	<i>ReLU</i>	<i>None</i>	60	60	128	73856
Pooling 3	<i>MaxPooling2D</i>	-	-	<i>None</i>	30	30	128	0
Konvolusi 4	<i>Conv2D</i>	3×3	<i>ReLU</i>	<i>None</i>	28	28	128	147584
Pooling 4	<i>MaxPooling2D</i>	-	-	<i>None</i>	14	14	128	0
Flatten	<i>Flatten</i>	-	-	<i>None</i>	25088	-	-	0
Fully Connected	<i>Dense</i>	-	<i>ReLU</i>	<i>None</i>	64	-	-	1605696
Fully Connected/ Output	<i>Dense</i>	-	<i>Softmax</i>	<i>None</i>	3	-	-	195

D. Training model

Pada tahap pelatihan model, terdapat beberapa parameter penting, seperti *learning_rate*, yang menentukan besaran penyesuaian bobot per iterasi, *batch_size*, yang menentukan jumlah sampel yang digunakan dalam setiap iterasi pelatihan, *optimizer*, yang menentukan algoritma untuk memperbarui bobot [19]. *Training model* pada penelitian ini dilakukan nilai *learning_rate* sebesar 0,0001 untuk membuat proses pelatihan berjalan dengan langkah yang cukup kecil sehingga model dapat belajar secara perlahan dan mempertahankan kestabilan proses pelatihan model. *Batch_size* yang pada proses pelatihan ini menggunakan nilai *default* yaitu 32 sehingga pada setiap iterasi akan menggunakan 30 sampel data, *optimizer* yang digunakan yaitu *Adaptive moment optimization (Adam)* yang merupakan pengembangan metode *Stochastic Gradient Descent (SGD)* dengan nilai bobot yang terus diperbarui, dan menggabungkan aspek-aspek terbaik *RMSProp* dan *Momentum*, untuk mencapai konvergensi yang cepat dan efisien [20].

E. Pengujian dan Evaluasi

Pengujian dan evaluasi kinerja model dalam melakukan klasifikasi jenis kayu berdasarkan citra serat kayu akan dilakukan menggunakan *Confusion Matrix* dan evaluasi akurasi. Dalam proses evaluasi model, *Confusion Matrix* digunakan untuk membandingkan hasil klasifikasi yang dihasilkan oleh model dengan data aktual yang mewakili nilai sebenarnya [15]. *Confusion Matrix* memungkinkan perhitungan metrik evaluasi *recall* dan akurasi yang memberikan gambaran secara numerik tentang kemampuan model melakukan klasifikasi dan mengevaluasi kinerja model secara keseluruhan. *Confusion matrix* pada penelitian ini yaitu *confusion matrix 3x3* yang dapat dilihat pada Tabel III.

TABEL IV
 CONFUSION MATRIX 3X3

Confusion matrix		Predicted		
		Nantu	Palapi	Uru
Actual	Nantu	TP	FP / FN	FP / FN
	Palapi	FP / FN	TP	FP / FN
	Uru	FP / FN	FP / FN	TP

Recall adalah metrik evaluasi yang mengukur seberapa banyak data pada suatu kelas yang berhasil diklasifikasikan dengan benar oleh model [21]. Akurasi (*Accuracy*) menggambarkan seberapa tepat model mengklasifikasikan data dengan benar dan tingkat kedekatan antara nilai prediksi dengan nilai sebenarnya (aktual) [22] Rumus perhitungan *recall* dan akurasi dapat dilihat pada persamaan (1) dan persamaan (2).

$$Recall = \frac{TP}{TP+FN} \quad (1)$$

$$Accuracy = \frac{TP}{TP+FP+FN} \quad (2)$$

TP = True Positive
 FP = False Positive
 FN = False Negative


III. HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan bahwa penerapan CNN dapat memberikan kinerja yang baik untuk klasifikasi jenis kayu berdasarkan citra serat kayu. Pada tahap pelatihan model dengan menggunakan data latih, diperoleh akurasi awal sebesar 48,26% yang kemudian meningkat secara bertahap hingga mencapai 97,06%. Nilai loss awal pada proses pelatihan adalah 0,9840 dan menurun secara bertahap hingga 0,0922 seiring dengan berlangsungnya proses pelatihan. Pada data validasi, akurasi awal yang diperoleh adalah 73,90% dan terus mengalami peningkatan hingga mencapai 95,60%, sedangkan nilai loss berangsur-angsur menurun dari 0,7086 menjadi 0,1301. Proses training model dapat dilihat pada Tabel V.

TABEL V
 PELATIHAN MODEL

Epoch	Training Loss	Training Accuracy	Validation loss	Validation Accuracy
1	0.9840	0.4826	0.7086	0.7390
2	0.4884	0.8307	0.4869	0.7704
3	0.3353	0.8780	0.4063	0.8616
4	0.3133	0.8896	0.3173	0.9088
5	0.2919	0.8980	0.2835	0.9057
6	0.2652	0.9064	0.2720	0.8868
7	0.2633	0.9075	0.3436	0.8805
8	0.2496	0.9064	0.2457	0.8931
9	0.2284	0.9127	0.2394	0.8836
10	0.2595	0.8927	0.2229	0.9088
11	0.2626	0.9117	0.2968	0.8774
12	0.2109	0.9106	0.2120	0.9088
13	0.2119	0.9138	0.2042	0.9340
14	0.1878	0.9274	0.1975	0.9088
15	0.1789	0.9264	0.2055	0.8962
16	0.2144	0.9201	0.2132	0.8962
17	0.2083	0.9169	0.3304	0.8836
18	0.1704	0.9264	0.2280	0.8899
19	0.1656	0.9359	0.3262	0.8836
20	0.2542	0.9022	0.3434	0.8805
21	0.2035	0.9253	0.3006	0.8836
22	0.2023	0.9180	0.2691	0.8836
23	0.1579	0.9411	0.2006	0.9057
24	0.1582	0.9348	0.3777	0.8679
25	0.1698	0.9285	0.2812	0.8836
26	0.1265	0.9506	0.1578	0.9434
27	0.1381	0.9443	0.1969	0.9277
28	0.1719	0.9295	0.1995	0.9025
29	0.1487	0.9443	0.2720	0.8805
30	0.1218	0.9548	0.2464	0.8899
31	0.1091	0.9632	0.1834	0.9308
32	0.1496	0.9411	0.3013	0.8868
33	0.1892	0.9380	0.2389	0.8899
34	0.1067	0.9685	0.1668	0.9277
35	0.1354	0.9443	0.3012	0.8774
36	0.1408	0.9453	0.2114	0.9182
37	0.1311	0.9485	0.2461	0.8868
38	0.0899	0.9674	0.2293	0.8962
39	0.0922	0.9706	0.1301	0.9560

Visualisasi perbandingan antara training loss dan validation loss serta training accuracy dan validation accuracy dapat dilihat pada Gambar 3.



Gambar. 3. Grafik Hasil Pelatihan Model

Evaluasi model dilakukan dengan menggunakan *confusion matrix* pada data pengujian. Hasil analisis *confusion matrix* menunjukkan bahwa model berhasil melakukan klasifikasi dengan baik pada masing-masing kelas kayu. *Confusion matrix* hasil pengujian model dapat dilihat pada Tabel V.

TABEL V
 CONFUSION MATRIX HASIL PENGUJIAN MODEL

Confusion matrix		Predicted		
		Nantu	Palapi	Uru
Actual	Nantu	99	6	0
	Palapi	0	105	0
	Uru	8	0	97

Pada kelas kayu nantu model berhasil mengklasifikasikan dengan benar 99 dari 105 sampel. 6 sampel data kayu nantu salah diklasifikasikan sebagai palapi, mengindikasikan adanya kesamaan fitur serat kayu antara kedua jenis kayu yang menyulitkan pembedaan. Meskipun nantu memiliki serat yang tidak terlalu padat, sedangkan palapi memiliki serat yang lebih padat, kedua jenis kayu ini memiliki kesamaan pada ciri seratnya yang cenderung searah. Hal ini dapat menjadi faktor yang menyebabkan terjadinya kesalahan klasifikasi.

Pada kelas kayu palapi, model berhasil mengklasifikasikan dengan benar seluruh 105 sampel. Tidak ada sampel data kayu palapi yang salah diklasifikasikan, menunjukkan ciri serat kayu palapi yang sangat jelas dan dapat dibedakan dengan baik dari nantu dan uru.

Pada kelas kayu uru, model berhasil mengklasifikasikan dengan benar 97 dari 105 sampel. 8 sampel data kayu uru salah diklasifikasikan sebagai nantu, mengindikasikan adanya kesamaan fitur serat kayu antara kedua jenis kayu yang menyulitkan pembedaan. Meskipun serat kayu nantu cenderung searah, sedangkan serat kayu uru cenderung tidak searah, kedua jenis kayu ini memiliki kesamaan dalam hal kepadatan serat kayu. Kayu nantu dan kayu uru memiliki serat kayu yang tidak terlalu padat. Hal ini dapat menjadi faktor yang menyebabkan terjadinya kesalahan klasifikasi. Beberapa data hasil pengujian model yang terklasifikasi dengan benar dan hasil pengujian model yang terklasifikasi dengan salah dapat dilihat pada Gambar 4.



Gambar. 4. Hasil Pengujian Model Klasifikasi

Dari hasil evaluasi model menggunakan *confusion matrix*, dapat dilakukan perhitungan persentase nilai recall dari setiap kelas kayu. Berikut Perhitungan persentase *recall* dari setiap kelas kayu :

Kelas kayu nantu :

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP+FN} * 100\% \\ &= \frac{99}{99+6} * 100\% \\ &= \frac{99}{105} * 100\% \\ &= 0,9428 * 100\% \end{aligned}$$

Recall= 94,28 %

Kelas kayu palapi :

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP+FN} * 100\% \\ &= \frac{105}{105+0} * 100\% \\ &= \frac{105}{105} * 100\% \\ &= 1 * 100\% \end{aligned}$$

Recall = 100%

Kelas kayu uru:

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP+FN} * 100\% \\ &= \frac{97}{97+8} * 100\% \\ &= \frac{97}{105} * 100\% \\ &= 0,9238 * 100\% \end{aligned}$$

Recall = 92,38%

Secara keseluruhan, model mencapai nilai akurasi sebesar 95,56% pada proses pengujian. Perhitungan persentase nilai akurasi dari hasil pengujian dapat dilihat pada perhitungan berikut :

$$\begin{aligned} \text{Accuracy} &= \frac{TP}{TP+FP+FN} * 100\% \\ &= \frac{(99+105+97)}{(99+105+97+6+8)} * 100\% \\ &= \frac{301}{315} * 100\% \\ &= 0,9556 * 100\% \end{aligned}$$

Accuracy = 95,56 %

Hasil - hasil yang didapatkan menunjukkan bahwa penelitian ini memiliki beberapa keunggulan dibandingkan dengan penelitian sebelumnya yang serupa. Salah satu keunggulan dari penelitian ini dibandingkan dengan penelitian sebelumnya yang dilakukan oleh [1] adalah nilai akurasi hasil pelatihan model yang lebih tinggi sebesar 97,06% (dibandingkan dengan nilai akurasi hasil pelatihan sebesar 87,5%) dan waktu pelatihan model yang lebih singkat, yaitu 39 *epoch*, dibandingkan dengan penelitian sebelumnya yang melakukan 600 *epoch*. Hasil pengujian model pada penelitian ini mencapai 95,65%, sedikit lebih tinggi dibandingkan dengan penelitian sebelumnya yang hanya mencapai 95%. Meskipun perbedaan akurasi tidak terlalu signifikan, namun penelitian ini dilakukan dengan menggunakan 315 sampel data uji, jauh lebih besar dibandingkan dengan penelitian sebelumnya yang hanya menggunakan 100 sampel data uji. Hal ini menunjukkan bahwa model yang dikembangkan dalam penelitian ini memiliki performa yang lebih baik dan lebih *robust*, serta dapat diaplikasikan pada dataset yang lebih besar dengan hasil yang konsisten. Kelemahan penelitian ini dibandingkan dengan penelitian sebelumnya terletak pada jumlah kelas objek klasifikasi yang lebih sedikit.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa dari 1584 data citra serat kayu dari 3 jenis kayu (nantu, palapi dan uru) yang telah dikumpulkan dari Mebel Alvian, dengan pembagian data latih dan data pengujian sebesar 80:20, arsitektur CNN yang terdiri dari 4 *Convolutional layers*, 4 *pooling Layers*, dan 2 *fully connected layers*, berhasil diimplementasikan untuk membangun model yang mampu mencapai nilai akurasi sebesar 97,06% dan *loss* sebesar 0,0922 pada proses pelatihan, menunjukkan bahwa model yang dihasilkan memiliki kinerja yang baik.

Hal ini didukung dengan hasil pengujian model menggunakan 315 sampel data yang berhasil mencapai nilai akurasi pengujian sebesar 95,56%, dengan nilai *recall* pada kelas kayu nantu sebesar 94,28%, pada kelas kayu palapi sebesar 100% dan pada kelas kayu uru sebesar 92,38%, yang menunjukkan model telah mampu melakukan klasifikasi jenis kayu berdasarkan citra serat kayu dengan sangat baik.

UCAPAN TERIMA KASIH

Ucapan terima kasih peneliti ucapkan kepada pihak Mebel Alvian atas dukungan dan kerja sama dalam penelitian ini. Kontribusi data dari Mebel Alvian sangat membantu kelancaran proses penelitian. Kerja sama yang baik antara peneliti dan pihak Mebel Alvian telah menjadi faktor penting dalam kesuksesan penelitian ini.

DAFTAR PUSTAKA

- [1] E. Y. Prastowo, "Pengenalan Jenis Kayu Berdasarkan Citra Makroskopik Menggunakan Metode Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 2, pp. 489–497, Aug. 2021, doi: 10.28932/jutisi.v7i2.3706.
- [2] B. Klaranita, G. Septilaila, I. S. Afifah, and M. Rahmayu, "Sistem Pendukung Keputusan Dalam Memilih Bahan Furniture Terbaik Menggunakan Metode Simple Additive Weighting (SAW)," *Jurnal Teknik Informatika*, vol. 7, no. 2, pp. 74–78, 2021.
- [3] Muthmainnah, A. S. Budi, and Asniati, "Karakteristik anatomi tiga jenis kayu asal Sulawesi Tengah," *ULIN: Jurnal Hutan Tropis*, vol. 7, no. 2, pp. 161–166, Sep. 2023, doi: 10.32522/ujht.v7i2.11111.
- [4] Neneng, N. Putri, and E. R. Susanto, "Klasifikasi Jenis Kayu Menggunakan Support Vector Machine Berdasarkan Ciri Tekstur Local Binary Pattern," *CYBERNETICS*, vol. 4, no. 02, pp. 93–100, 2020.
- [5] A. Putri, R. Soekarta, and I. Amri, "Sistem pendukung keputusan pemilihan beberapa jenis kayu untuk kerajinan meuble dengan metode simple additive weighting," *Framework: Jurnal Ilmu Komputer dan Informatika*, vol. 01, no. 02, pp. 156–161, 2023.
- [6] D. P. Utomo and Mesran, "Analisis Komparasi Metode Klasifikasi Data Mining dan Reduksi Atribut Pada Data Set Penyakit Jantung," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 4, no. 2, pp. 437–444, Apr. 2020, doi: 10.30865/mib.v4i2.2080.
- [7] I. Romli and A. Turmudi, "Penentuan Jadwal Overtime Dengan Klasifikasi Data Karyawan Menggunakan Algoritma C4.5," *Jurnal Sains Komputer & Informatika (J-SAKTI)*, vol. 4, no. 2, pp. 694–702, 2020.
- [8] I. B. Trisno and M. A. Raharja, "Webinar Artificial Intelligence dan Machine Learning," *JPM Jurnal Pengabdian Mandiri*, vol. 2, no. 11, pp. 2307–2315, 2023.
- [9] N. R. Sari and Y. Mar'atullatifah, "Penerapan Multilayer Perceptron untuk Identifikasi Kanker Payudara," *Jurnal Cakrawala Ilmiah*, vol. 2, no. 8, pp. 3261–3268, 2023.
- [10] E. Hermawan, "Klasifikasi Pengenalan Wajah Menggunakan Masker atau Tidak Dengan Mengimplementasikan Metode CNN (Convolutional Neural Network)," *JURNAL INDUSTRI KREATIF DAN INFORMATIKA SERIES (JIKIS)*, vol. 1, no. 1, pp. 33–43, 2021.
- [11] R. A. Imaduddin and T. N. Suharsono, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Citra Jamur Berbasis Mobile," *Innovative: Journal Of Social Science Research*, vol. 3, no. 5, pp. 864–875, 2023.
- [12] F. Ramadhani, A. Satria, and Salamah, "Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak," *sudo Jurnal Teknik Informatika*, vol. 2, no. 4, pp. 167–175, Dec. 2023, doi: 10.56211/sudo.v2i4.408.
- [13] M. F. Naufal, "Analisis Perbandingan Algoritma SVM, KNN, dan CNN untuk Klasifikasi Citra Cuaca," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, pp. 311–318, 2021, doi: 10.25126/jtik.202184553.
- [14] F. Huda and P. M. Pajar Kharisma, "Klasifikasi Jenis Buah Pisang Menggunakan Algoritma Convolutional Neural Network," *Journal of Artificial Intelligence and Technology Information*, vol. 1, no. 3, pp. 100–105, 2023.
- [15] N. M. Y. D. Rahayu, M. W. Antara Kesiman, and I. G. A. Gunadi, "Identifikasi Jenis Kayu Berdasarkan Fitur Tekstur Local Binary Pattern Menggunakan Metode Learning Vector Quantization," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 10, no. 3, pp. 157–166, Dec. 2021, doi: 10.23887/janapati.v10i3.40804.
- [16] W. Bismi and M. Qomaruddin, "Klasifikasi Citra Genus Panthera Menggunakan Pendekatan Deep learning Berbasis Convolutional Neural Network (CNN)," *Jurnal Informatika dan Rekayasa Perangkat Lunak*, vol. 5, no. 2, pp. 172–179, 2023.
- [17] A. Prayoga, Maimunah, P. Sukmasetya, M. R. A. Yudianto, and R. Abul Hasani, "Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta," *Journal of Applied Computer Science and Technology*, vol. 4, no. 2, pp. 82–89, Nov. 2023, doi: 10.52158/ja-cost.v4i2.486.
- [18] I. Wulandari, H. Yasin, and T. Widiharih, "Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma Convolutional Neural Network (CNN)," *JURNAL GAUSSIAN*, vol. 9, no. 3, pp. 273–282, 2020, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [19] N. Fadlia and R. Kosasih, "Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network(CNN)," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 24, no. 3, pp. 207–215, 2019, doi: 10.35760/tr.2019.v24i3.2397.
- [20] N. S. Mahajaya, P. Desiana, W. Ayu, and R. R. Huizen, "Pengaruh Optimizer Adam, AdamW, SGD, dan LAMB terhadap Model Vision Transformer pada Klasifikasi Penyakit Paru-paru," *SPINTER*, vol. 1, no. 2, pp. 818–823, 2024, [Online]. Available: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>,
- [21] B. P. Pratiwi, A. S. Handayani, and Sarjana, "Pengaruh Kinerja Sistem Kualitas Udara Dengan Teknologi WSN Menggunakan Confusion Matrix," *JURNAL INFORMATIKA UPGRIS*, vol. 6, no. 2, pp. 66–75, 2020.
- [22] L. Yuwono, M. E. Fadillah, M. Indrayani, W. Maesarah, A. Ramadhan, and S. F. Panjaitan, "Klasifikasi Pendapatan Pedagang Kaki Lima Dan Pelaku Usaha Online Akibat Dampak Covid-19 Menggunakan Metode Naive Bayes," *Bulletin of Applied Industrial Engineering Theory*, vol. 2, no. 1, pp. 1–6, 2021.