

APPLICATION OF VGG16 ARCHITECTURE IN WOOD TYPE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK

Nurul Anggun Afiah^{*1}, Syahrullah², Rizka Ardiansyah³, Rahmah Laila⁴, Rinianty Pohontu⁵

^{1,3,4,5}Informatics Engineering, Faculty of Engineering, Universitas Tadulako, Indonesia

²Information System, Faculty of Engineering, Universitas Tadulako, Indonesia

Email: ¹anggunnurul0@gmail.com, ²syahroellah.ms@gmail.com, ³rizka@Untad.ac.id,

⁴lailarahmah.ella@gmail.com, ⁵riniantyinformatika@gmail.com

(Article received: October 02, 2024; Revision: November 06, 2024; published: February 20, 2025)

Abstract

Wood is an important natural resource in construction and the furniture industry, with various types possessing unique characteristics. The selection of wood types is often done manually, which is prone to errors that can negatively impact the working process, product quality, and the sustainability of the forests that source the wood. Therefore, this research aims to improve classification accuracy through the application of technology. This study utilizes Convolutional Neural Network (CNN) with the VGG16 architecture to process images in analyzing the visual characteristics of wood, with the goal of building a model capable of classifying wood types based on images. The dataset used consists of 1,584 samples of wood images sourced from Kaggle. Four models were tested with variations in the training and validation data splits, as well as the use of Adam and Adamax optimizers, over 100 epochs. Model 1 achieved a training accuracy of 96.68% and a testing accuracy of 98.10%. Model 2, with a training accuracy of 99.47% and a testing accuracy of 98.41%, showed the best performance. Models 3 and 4 also yielded testing accuracies of 97.46% and 97.78%, respectively. The results of this study indicate that the application of CNN with the VGG16 architecture can enhance the effectiveness of wood type classification and contribute to more accurate and efficient wood selection practices.

Keywords: Clasification, Convolutional Neural Network, Image, VGG-16, wood Types.

PENERAPAN ARSITEKTUR VGG16 DALAM KLASIFIKASI JENIS KAYU MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Abstrak

Kayu merupakan sumber daya alam penting dalam konstruksi dan industri furnitur, dengan berbagai jenis yang memiliki karakteristik unik. Pemilihan jenis kayu sering dilakukan secara manual, yang rentan terhadap kesalahan yang dapat berdampak negatif pada proses pengerjaan, kualitas hasil produk serta keberlanjutan hutan sumber dari kayu itu sendiri. Oleh karena itu, penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi dengan Penerapan teknologi. Penelitian ini memanfaatkan *Convolutional Neural Network* (CNN) dengan arsitektur VGG16 untuk memproses citra dalam menganalisis karakteristik visual kayu, dengan tujuan membangun model yang mampu mengklasifikasikan jenis kayu berdasarkan citra. *Dataset* yang digunakan terdiri dari 1.584 sampel citra kayu yang berasal dari *Kaggle*. Empat model diuji dengan variasi pembagian data latih dan validasi, serta penggunaan *optimizer* Adam dan Adamax, selama 100 epoch. Model 1 menunjukkan akurasi pelatihan 96,68% dan akurasi pengujian 98,10%. Model 2, dengan akurasi pelatihan 99,47% dan akurasi pengujian 98,41%, menunjukkan performa terbaik. Model 3 dan Model 4 juga menghasilkan akurasi pengujian masing-masing 97,46% dan 97,78%. Hasil penelitian ini menunjukkan bahwa penerapan CNN dengan arsitektur VGG16 mampu meningkatkan efektivitas klasifikasi jenis kayu, serta memberikan kontribusi terhadap praktik pemilihan kayu yang lebih akurat dan efisien.

Kata kunci: Citra, Convolutional Neural Network, Jenis Kayu, Klasifikasi, VGG-16.

1. PENDAHULUAN

Kayu adalah sumber daya alam yang sangat berharga dan memainkan peran krusial dalam berbagai sektor, terutama konstruksi dan industri

furnitur [1]. Dengan kontribusi yang signifikan terhadap ekonomi, kayu digunakan mulai dari skala rumah tangga hingga perdagangan internasional, menjadi bahan utama dalam pembangunan rumah,

pembuatan furnitur, dan kerajinan tangan [2]. Meskipun saat ini terdapat alternatif seperti baja ringan, *Medium Density Fiberboard* (MDF) dan papan kalsi yang semakin populer, kayu tetap menjadi pilihan utama. Keindahan estetika, ketahanan, serta kemudahan dalam pengolahannya menjadikan kayu tidak tergantikan dalam banyak aplikasi [3].

Di Indonesia, keberagaman jenis kayu, baik yang bersifat lokal maupun eksotik, memperkaya pilihan bahan baku untuk industri [4]. Setiap jenis kayu memiliki karakteristik unik, dengan kelebihan dan kekurangan tertentu yang menentukan kegunaannya. Oleh karena itu, pemahaman mendalam tentang karakteristik serta aplikasi berbagai jenis kayu sangat penting dalam memilih jenis kayu yang tepat. Hal ini bertujuan untuk memaksimalkan potensi sumber daya kayu [5].

Namun, tantangan yang dihadapi saat ini adalah proses pemilihan jenis kayu yang sering dilakukan secara manual melalui pengamatan visual. Proses ini memerlukan latihan intensif dan waktu yang cukup lama untuk mencapai tingkat keahlian yang memadai. Keterbatasan kemampuan klasifikasi visual pada individu yang belum terampil dapat mengakibatkan kesalahan dalam pemilihan kayu, sehingga penggunaan kayu tidak optimal dan tidak sesuai dengan fungsinya. Ini menjadi tantangan yang perlu diatasi untuk meningkatkan efisiensi dan efektivitas dalam pemanfaatan sumber daya kayu. [2]. Kesalahan dalam memilih jenis kayu dapat memiliki dampak yang signifikan pada penurunan kualitas produk akhir yang dapat merusak reputasi produsen. Selain itu, pemilihan kayu yang tidak sesuai dapat meningkatkan tingkat kesulitan dalam proses produksi, memperpanjang waktu pengerjaan, dan mengakibatkan pemborosan sumber daya. Dampak ini juga berpotensi memengaruhi keberlanjutan pemanfaatan hutan, yang menjadi sumber bahan baku kayu olahan[6].

Untuk mengatasi masalah ini, salah satu metode yang dapat diterapkan adalah klasifikasi. Metode ini digunakan untuk menemukan pola-pola yang membedakan kelas data yang berbeda, yang bertujuan untuk menentukan kategori objek baru berdasarkan perilaku dan karakteristiknya kedalam suatu kelompok yang memiliki perilaku dan karakteristik yang sama. Banyak aturan dapat dibuat dengan teknik klasifikasi untuk membantu mengklasifikasikan data baru dengan lebih akurat. *K-Nearest Neighbor* (KNN), *Decision Tree*, *Naive Bayes*, *Support Vector Machine* (SVM) dan *Artificial Neural Network* (ANN) adalah beberapa algoritma yang biasa digunakan untuk klasifikasi [7].

ANN merupakan algoritma yang berusaha meniru struktur otak manusia untuk mengikuti cara kerja otak manusia saat melakukan sesuatu [8]. ANN terdiri dari kumpulan *neuron* yang saling terhubung dan memiliki kemampuan untuk mengirimkan sinyal aktivasi, mirip dengan susunan otak manusia [9].

ANN dapat memodelkan operasi yang sangat kompleks dan *non-linear* karena arsitekturnya yang kompleks. Memproses data pelatihan dan mengatur parameter model menggunakan berbagai metode pelatihan memungkinkan model ANN untuk dilatih secara bertahap hingga keluaran model mencapai tujuan yang diinginkan [10].

Salah satu jenis ANN yang dapat digunakan untuk pemrosesan dan ekstraksi data dari kumpulan data, khususnya data citra adalah *Convolutional Neural Network* (CNN). CNN bekerja dengan mengubah citra digital menjadi matriks dua dimensi dengan nilai tersendiri untuk setiap piksel, yang memungkinkan CNN untuk memperoleh karakteristik citra. Selanjutnya, melalui lapisan konvolusi, CNN mengekstraksi informasi dari data citra tersebut [11]. Dengan menggunakan fitur pembagian bobot, CNN dapat mengurangi jumlah parameter yang diperlukan dalam jaringan pelatihan, yang membantu mencegah generalisasi yang berlebihan yang dapat menyebabkan *overfitting*. Selain itu, CNN dapat mempelajari dan memproses lapisan ekstraksi dan klasifikasi secara bersamaan, yang menghasilkan keluaran model yang sangat bergantung pada fitur yang diekstraksi [12]. Dalam beberapa situasi tertentu, CNN mampu mengklasifikasikan citra lebih baik daripada algoritma klasifikasi lain seperti SVM dan KNN [13].

Penerapan algoritma Convolutional Neural Network (CNN) dalam klasifikasi data citra telah ditunjukkan dalam penelitian yang dilakukan oleh [14] yang mengklasifikasikan warna pada kematangan buah kopi kuning menggunakan CNN dengan arsitektur *Inception v3*. Penelitian ini menggunakan data citra buah kopi kuning berjumlah 1380 citra yang kemudian dibagi menjadi 984 citra sebagai data latih, 246 citra sebagai data validasi dan 150 citra sebagai data uji. Penelitian ini mendapatkan hasil akhir berupa model cnn yang memiliki nilai akurasi sebesar 92%.

Selanjutnya, penelitian lain yang dilakukan oleh [15] berfokus pada klasifikasi penyakit pada tanaman tomat melalui citra dengan menggunakan arsitektur VGG-16. Penelitian ini menggunakan 10519 citra sebagai data latih dan 1100 citra sebagai data validasi yang menghasilkan nilai akurasi sebesar 98% pada data latih dan 82% pada data validasi.

Selain itu, penerapan CNN juga dapat dilihat dalam penelitian oleh [3] yang melakukan klasifikasi terhadap 4 jenis kayu menggunakan CNN dengan arsitektur VGG-16 yang disederhanakan. Penelitian ini menggunakan 733 citra sebagai data latih, 207 citra sebagai data validasi dan 100 citra sebagai data uji. Penelitian ini menghasilkan model CNN yang memiliki nilai akurasi sebesar 95%.

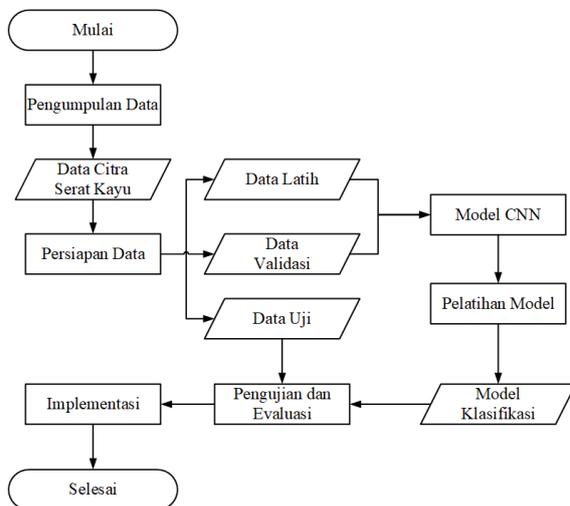
Dari penelitian – penelitian tersebut terbukti bahwa CNN mampu mengekstrak fitur visual yang relevan sehingga dapat digunakan secara efektif untuk klasifikasi pada data citra dan mampu

menghasilkan model klasifikasi dengan tingkat akurasi tinggi.

Penelitian ini bertujuan mengembangkan dan menerapkan CNN untuk meningkatkan akurasi klasifikasi jenis kayu, sehingga dapat membantu dalam pemilihan jenis kayu yang tepat dan optimal. Penelitian ini diharapkan dapat memberikan kontribusi signifikan terhadap efisiensi pemanfaatan sumber daya kayu.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Penelitian difokuskan pada penerapan arsitektur VGG-16 untuk mengklasifikasi jenis kayu melalui citra. Tahapan penelitian yang dilakukan pada penelitian ini dapat dilihat pada Gambar 1, berikut.



Gambar 1. Flowchart Penelitian

2.1. Pengumpulan Data

Proses pengumpulan data sangat penting untuk penelitian ini karena kualitas dataset yang digunakan akan memengaruhi proses dan hasil penelitian. Data harus dikumpulkan dari sumber yang relevan untuk memastikan dataset yang digunakan representatif dan mencakup variasi yang cukup [16]. Pada penelitian ini, data dikumpulkan dari platform *Kaggle*, yang merupakan penyedia data publik di internet. Data yang dikumpulkan merupakan data citra serat kayu dengan jumlah total 1.584 data citra.

2.2. Persiapan Data

Persiapan data adalah metode yang umum digunakan dalam pengembangan model *machine learning* yang melibatkan pemuatan dan penyesuaian data untuk kemudian disimpan ke dalam objek data sehingga dapat digunakan secara berulang pada tahapan pelatihan dan pengujian model [17]. Dalam penelitian ini, proses persiapan data mencakup pembagian data menjadi tiga sub-bagian serta augmentasi data untuk mengoptimalkan informasi

dan menyesuaikan data sebelum digunakan dalam tahapan-tahapan berikutnya [16].

2.3. Pemodelan

Beberapa parameter, seperti jumlah lapisan konvolusional, ukuran *filter*, dan *pooling*, harus dipertimbangkan saat membuat arsitektur model. Parameter-parameter tersebut menjadi faktor memengaruhi kompleksitas fitur yang dapat dipelajari oleh model, semakin banyak jumlah lapisan konvolusional memungkinkan ekstraksi fitur yang lebih mendalam. Ukuran filter yang sesuai membantu dalam menangkap detail yang relevan, sementara *pooling* berfungsi untuk mengurangi dimensi data dan mempercepat proses pelatihan. Selain itu, fungsi aktivasi dan jumlah *neuron* pada lapisan *fully-connected* juga memiliki peran krusial, karena menentukan kemampuan model dalam klasifikasi dan pengenalan pola. Pemilihan parameter yang tepat akan meningkatkan efektivitas model secara keseluruhan [18].

Arsitektur model CNN yang digunakan pada penelitian ini adalah VGG 16, yang merupakan arsitektur CNN yang kompleks dan mampu mengekstrak fitur-fitur penting dari gambar untuk klasifikasi. Arsitektur ini telah terbukti sangat efektif dalam berbagai kompetisi dan aplikasi di bidang pengenalan citra [19].

2.4. Pelatihan Model

Pelatihan Model adalah proses esensial dalam *Machine Learning* yang bertujuan untuk mengoptimalkan model agar dapat melakukan prediksi dengan akurat berdasarkan data yang diberikan, dengan kata lain pelatihan model merupakan proses yang kompleks dan iteratif yang mencakup berbagai langkah untuk mengajarkan model bagaimana berfungsi dengan baik [20].

Pelatihan model pada penelitian ini dilakukan selama 100 iterasi (*epoch*) untuk memastikan model memiliki waktu yang cukup untuk mempelajari pola dari data dan menghindari risiko *overfitting*. Ukuran *batch* yang digunakan adalah 32, karena memberikan stabilitas yang lebih baik dalam pembaruan parameter model serta efisiensi dalam pemanfaatan sumber daya komputasi, yang memungkinkan proses pelatihan model berlangsung lebih cepat. *Loss function* yang digunakan pada penelitian ini adalah *categorical cross entropy* yang merupakan *loss function* untuk klasifikasi multi-kelas yang di desain untuk mengukur perbedaan antara 2 distribusi probabilitas [21]. Penelitian ini menerapkan dua jenis optimizer, yaitu *Adaptive Moment Estimation* (Adam) dan *Adaptive Moment Estimation with Infinity Norm* (Adamax). Adam merupakan metode optimisasi yang menggunakan *gradien* dan *varians gradien* untuk menyesuaikan parameter pembelajaran. Hal ini memungkinkan Adam untuk mempertahankan stabilitas dalam pelatihan model, sementara Adamax

merupakan sebuah variasi dari Adam, menggunakan norma yang lebih fleksibel untuk menyesuaikan kondisi pembelajaran. Kedua metode ini meningkatkan efisiensi dalam pelatihan model dan menghasilkan prediksi yang lebih akurat. Adam dan Adamax adalah metode optimisasi yang sangat umum digunakan [22].

2.5. Pengujian dan Evaluasi

Pengujian dan evaluasi adalah langkah penting dalam pengembangan model machine learning. Pengujian merujuk pada proses model diuji menggunakan data yang belum pernah dilihat sebelumnya yang bertujuan untuk menilai kemampuan model dalam membuat prediksi yang akurat di luar data pelatihan. Sedangkan evaluasi merupakan proses yang melibatkan analisis hasil pengujian yang telah dilakukan sebelumnya [16].

Pada tahap evaluasi model, *Confusion Matrix* digunakan untuk melihat perbedaan antara hasil klasifikasi model dengan data nyata yang menunjukkan nilai sebenarnya. *Confusion Matrix* memungkinkan perhitungan nilai akurasi, yang memberikan gambaran numerik tentang kemampuan model untuk melakukan klasifikasi dan menilai kinerjanya secara keseluruhan [16]. *Confusion Matrix* yang digunakan pada penelitian ini dapat dilihat pada Tabel 2.

Tabel 2. *Confusion Matrix*

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

Accuracy atau ketepatan, menunjukkan seberapa tepat model mengklasifikasikan data dan seberapa jauh perbedaan nilai prediksi dan nilai sebenarnya (aktual) [23]. Rumus perhitungan nilai akurasi dapat dilihat pada persamaan berikut.

$$Accuracy = \frac{TP}{TP+FP+FN} \tag{1}$$

2.6. Penerapan

Penerapan atau pengaplikasian model merupakan proses pengoperasian suatu model machine learning di lingkungan produksi yang mencakup berbagai langkah, seperti mengintegrasikan model ke dalam aplikasi atau sistem dan memastikan model dapat beroperasi secara efisien [24].

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini berjumlah 1.584 sampel, yang terdiri dari tiga kelas atau jenis kayu, yaitu kayu Nantu, kayu Palapi, dan kayu Uru. Dengan resolusi gambar sebesar 1200 ×

1200 *pixel* pada setiap sampel data. Contoh sampel data dapat dilihat pada gambar berikut.



Gambar 2. Contoh sampel data

3.2. Persiapan Data

Pada penelitian ini persiapan data dimulai dengan membagi data set menjadi dua bagian utama, yaitu 80% untuk data pelatihan dan 20% untuk data pengujian. Tujuan dari pembagian ini adalah untuk memastikan bahwa model yang dikembangkan dapat dilatih dan diuji secara independen, sehingga evaluasi kinerjanya menjadi lebih akurat.

Selanjutnya, data pelatihan akan dibagi kembali menjadi dua subbagian, yaitu data pelatihan dan data validasi. Pada tahap ini, dua skema pembagian data diterapkan untuk memastikan keandalan model. Skema pertama membagi data dengan rasio 70:30, di mana 70% dari data pelatihan digunakan untuk melatih model, dan 30% digunakan sebagai data validasi. Skema kedua menerapkan rasio 80:20, di mana 80% dari data pelatihan digunakan untuk pelatihan model dan 20% untuk validasi. Dua skema pembagian data ini dilakukan sebagai percobaan untuk mendapatkan model dengan kinerja terbaik. rincian pembagian jumlah sampel data dapat dilihat pada table berikut.

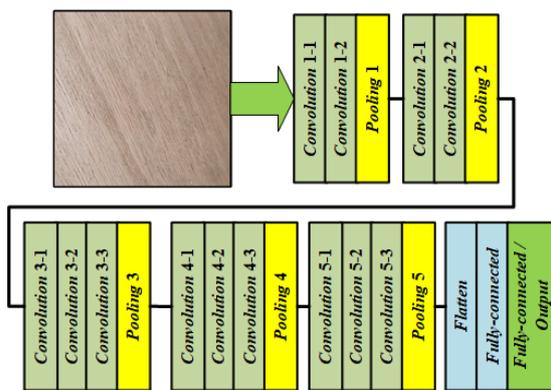
Tabel 1. Pembagian data

Skema	%	Data Pelatihan	Data Validasi	Data Pengujian
1	(70:30) : 20	888	381	315
2	(80:20) : 20	1017	252	315

Setelah pembagian data, dataset diproses kedalam image generator dengan mengubah skala warnanya dengan membagi nilai piksel dengan 255 dan mengubah ukuran setiap sampel menjadi 224x224 piksel. Selain itu, *augmentasi* gambar diterapkan melalui parameter seperti *shear_range* dan *zoom_range*, yang memungkinkan variasi dalam sudut dan *zoom* gambar, serta penggunaan *fill_mode* untuk mengisi area kosong dengan refleksi gambar.

3.3. Pemodelan

Struktur dari model yang digunakan pada penelitian ini terdiri dari beberapa lapisan konvolusi yang diikuti oleh dua lapisan *fully-Connected*, di mana setiap lapisan memiliki bobot yang berbeda untuk mempelajari representasi data yang lebih kompleks. Fungsi aktivasi yang digunakan adalah *Rectified Linear Unit* (ReLU), yang meningkatkan performa jaringan pada lapisan tersembunyi. Untuk menghasilkan *output* klasifikasi, VGG-16 menerapkan fungsi aktivasi *softmax* pada lapisan terakhir, memungkinkan model menangani klasifikasi multikelas dengan efisien [19]. Susunan arsitektur VGG-16 dapat dilihat pada Gambar 3 berikut.



Gambar 3. Diagram Alur Arsitektur VGG-16

3.4. Pelatihan Model

Dua skema pembagian data dan dua metode optimisasi yang digunakan pada penelitian ini menghasilkan 4 variasi model, rincian terkait model tersebut dapat dilihat pada Tabel 2 Berikut.

Tabel 2. Variasi Model

Variasi	Skema Pembagian data	Optimizer
Model 1	1	Adam
Model 2	1	Adamax
Model 3	2	Adam
Model 4	2	Adamax

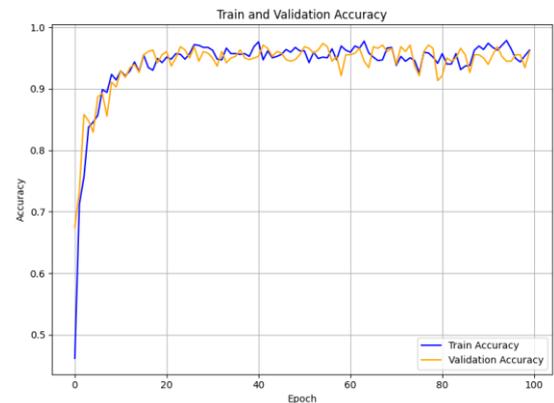
3.4.1. Hasil Pelatihan Model 1

Pada tahap pelatihan model 1 menghasilkan model dengan nilai akurasi sebesar 96,68%. Rincian hasil pelatihan model ini dapat dilihat pada Tabel 3.

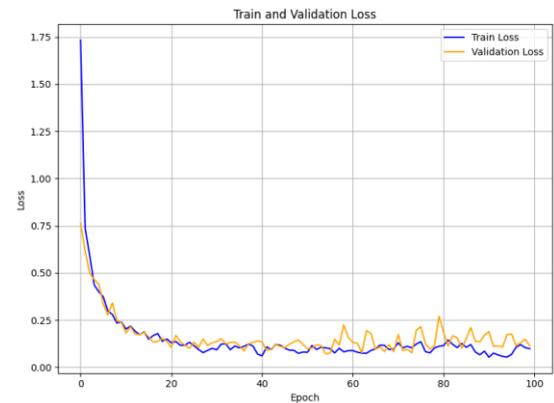
Tabel 3. Hasil Pelatihan Model 1

Epoch	Train. Loss	Train. Accuracy	Val. Loss	Val. Accuracy
1	2.5601	0.4101	0.7629	0.6745
2	0.7627	0.7042	0.6149	0.7349
3	0.6015	0.7511	0.4973	0.8583
4	0.4672	0.8306	0.4654	0.8478
5	0.4022	0.8488	0.4395	0.8294
...
96	0.0797	0.9536	0.1760	0.9449
97	0.0969	0.9596	0.1137	0.9554
98	0.1446	0.9384	0.1296	0.9554
99	0.1311	0.9486	0.1482	0.9344
100	0.0876	0.9668	0.1124	0.9606

Dari tabel diatas dapat dilihat bahwa dalam proses pelatihan menggunakan data latih, model 1 memperoleh nilai akurasi awal sebesar 41,01 % yang meningkat seiring dengan jalannya proses pelatihan hingga mencapai nilai akurasi sebesar 96,68 %. Sedangkan nilai loss awal pada model ini sebesar 2.5601 yang berangsur-angsur menurun hingga mendapatkan nilai loss akhir sebesar 0.0876 dan pada data validasi, model 1 memperoleh nilai akurasi awal sebesar 67,45% yang terus meningkat hingga 96,06% dengan nilai *loss* awal sebesar 0,7629 yang terus menurun hingga menjadi 0.1124 pada akhir pelatihan model. Grafik proses pelatihan model 1 dapat dilihat pada Gambar 4 dan 5 berikut.



Gambar 4. Training & validation Accuracy Model 1



Gambar 5. Training & Validation Loss Model 1.

3.4.2. Hasil Pelatihan Model 2

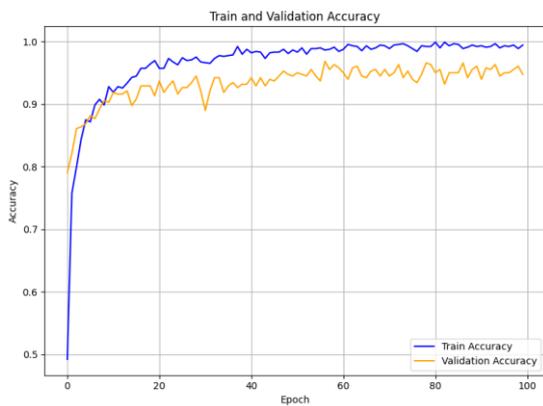
Pada tahap pelatihan model 2 menghasilkan model dengan nilai akurasi sebesar 99,47%. Rincian hasil pelatihan model ini dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pelatihan Model 1

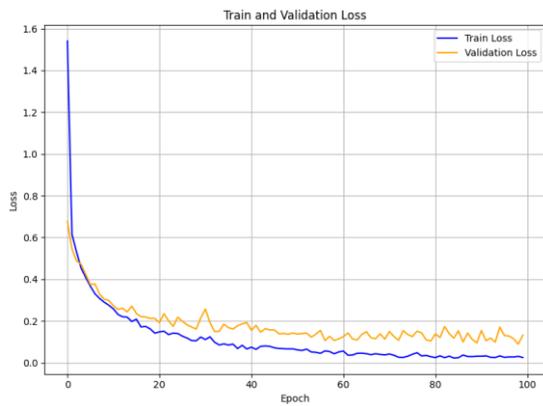
Epoch	Train. Loss	Train. Accuracy	Val. Loss	Val. Accuracy
1	2.1515	0.4156	0.6785	0.7900
2	0.6543	0.7171	0.5451	0.8215
3	0.5599	0.7754	0.4877	0.8609
4	0.4583	0.8449	0.4712	0.8635
5	0.4266	0.8513	0.4230	0.8688
...
96	0.0311	0.9901	0.1298	0.9501
97	0.0292	0.9908	0.1281	0.9501
98	0.0227	0.9948	0.1148	0.9554
99	0.0281	0.9903	0.0889	0.9606

100	0.0277	0.9947	0.1317	0.9475
-----	--------	--------	--------	--------

Dari tabel diatas dapat dilihat bahwa dalam proses pelatihan menggunakan data latih, model 2 memperoleh nilai akurasi awal sebesar 41,56 % yang meningkat seiring dengan jalannya proses pelatihan hingga mencapai nilai akurasi sebesar 99,47 %. Sedangkan nilai *loss* awal pada model ini sebesar 2.1515 yang berangsur-angsur menurun hingga mendapatkan nilai *loss* akhir sebesar 0.0277 dan pada data validasi, model 1 memperoleh nilai akurasi awal sebesar 67,85% yang terus meningkat hingga 94,75% dengan nilai *loss* awal sebesar 0,6785 yang terus menurun hingga menjadi 0.1317 pada akhir pelatihan model. Grafik proses pelatihan model 2 dapat dilihat pada Gambar 6 dan 7 berikut.



Gambar 6. Training & Validation Accuracy Model 2



Gambar 7. Training & Validation Loss Model 2

3.4.3. Hasil Pelatihan Model 3

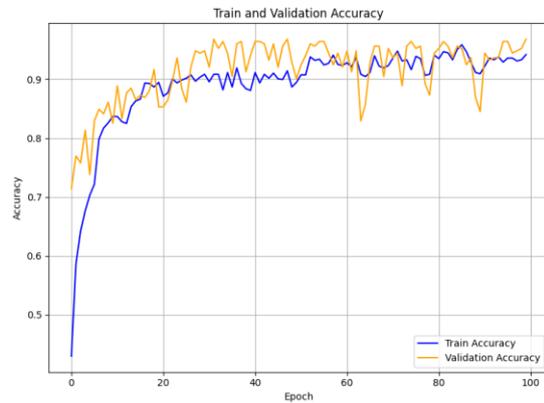
Pada tahap pelatihan model 3 menghasilkan model dengan nilai akurasi sebesar 94,44%. Rincian hasil pelatihan model ini dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pelatihan Model 1

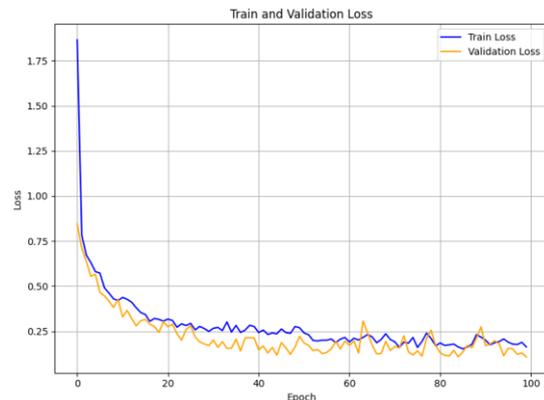
Epoch	Train. Loss	Train. Accuracy	Val. Loss	Val. Accuracy
1	3.1165	0.3569	0.8446	0.7143
2	0.8111	0.5829	0.7111	0.7698
3	0.6890	0.6314	0.6374	0.7579
4	0.6444	0.6782	0.5544	0.8135
5	0.5636	0.7058	0.5659	0.7381
...
96	0.1908	0.9390	0.1549	0.9643
97	0.1943	0.9292	0.1512	0.9444

98	0.1956	0.9221	0.1208	0.9484
99	0.1679	0.9456	0.1294	0.9524
100	0.1574	0.9444	0.1070	0.9683

Dari tabel diatas dapat dilihat bahwa dalam proses pelatihan menggunakan data latih, model 3 memperoleh nilai akurasi awal sebesar 35,69 % yang meningkat seiring dengan jalannya proses pelatihan hingga mencapai nilai akurasi sebesar 94,44 %. Sedangkan nilai *loss* awal pada model ini sebesar 3.1165 yang berangsur-angsur menurun hingga mendapatkan nilai *loss* akhir sebesar 0.1574 dan pada data validasi, model 1 memperoleh nilai akurasi awal sebesar 71,43% yang terus meningkat hingga 96,83% dengan nilai *loss* awal sebesar 0,8446 yang terus menurun hingga menjadi 0.1070 pada akhir pelatihan model. Grafik proses pelatihan model 3 dapat dilihat pada Gambar 8 dan 9 berikut.



Gambar 8. Training & Validation Accuracy Model 3



Gambar 9. Training & Validation Loss Model 3

3.4.4. Hasil Pelatihan Model 4

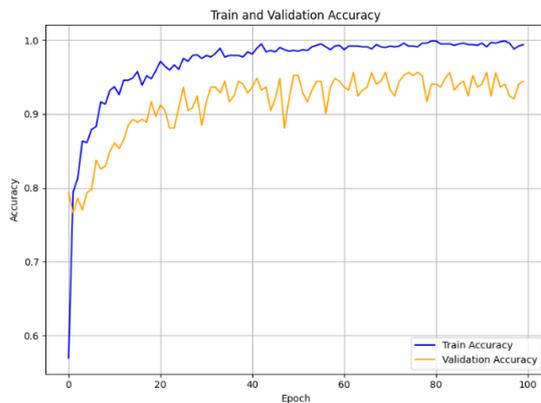
Pada tahap pelatihan model 4 menghasilkan model dengan nilai akurasi sebesar 99,59%. Rincian hasil pelatihan model ini dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pelatihan Model 1

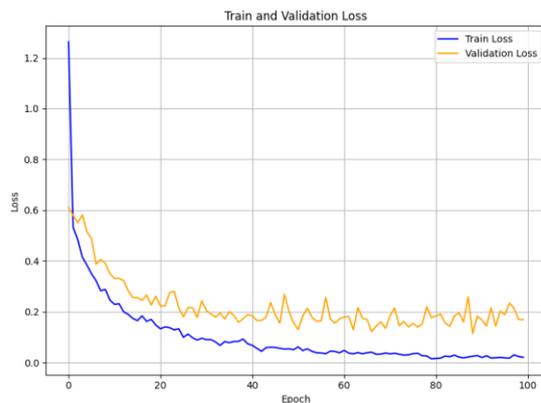
Epoch	Train. Loss	Train. Accuracy	Val. Loss	Val. Accuracy
1	1.9739	0.4666	0.6111	0.7937
2	0.5571	0.7854	0.5793	0.7659
3	0.4875	0.8132	0.5510	0.7857
4	0.4189	0.8566	0.5812	0.7698
5	0.3969	0.8522	0.5146	0.7937
...

96	0.0156	0.9997	0.1888	0.9405
97	0.0130	0.9992	0.2343	0.9246
98	0.0243	0.9913	0.2135	0.9206
99	0.0258	0.9904	0.1694	0.9405
100	0.0198	0.9959	0.1688	0.9444

Dari tabel diatas dapat dilihat bahwa dalam proses pelatihan menggunakan data latih, model 4 memperoleh nilai akurasi awal sebesar 46,66 % yang meningkat seiring dengan jalannya proses pelatihan hingga mencapai nilai akurasi sebesar 99,59 %. Sedangkan nilai *loss* awal pada model ini sebesar 1.9739 yang berangsur-angsur menurun hingga mendapatkan nilai *loss* akhir sebesar 0.0198 dan pada data validasi, model 1 memperoleh nilai akurasi awal sebesar 79,37% yang terus meningkat hingga 94,44% dengan nilai *loss* awal sebesar 0,6111 yang terus menurun hingga menjadi 0.1070 pada akhir pelatihan model. Grafik proses pelatihan model 4 dapat dilihat pada Gambar 10 dan 11 berikut.



Gambar 10. Training & Validation Accuracy Model 4



Gambar 11. Training & Validation Loss Model 4

3.5. Pengujian dan Evaluasi

Pengujian model dilakukan menggunakan data uji yang berjumlah 315 sampel data yang terdiri dari 105 data untuk setiap kelas kayu. Data baru yang belum pernah diolah oleh model sebelumnya dengan tujuan untuk memastikan bahwa model yang dibangun tidak hanya baik dalam memprediksi data latih dan validasi, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru.

3.5.1. Hasil Pengujian dan Evaluasi Model 1

Dari 315 model 1 berhasil mengklasifikasikan sebanyak 309 sampel dengan benar dan 6 sampel terklasifikasi kedalam kelas yang salah. Rincian lebih jelas terkait pengujian model 1 dapat dilihat pada Tabel 6 berikut.

Tabel 6. Confusion Matrix Model 1

		Actual		
		Nantu	Palapi	Uru
Predicted	Nantu	102	0	3
	Palapi	0	105	0
	Uru	3	0	102

Hasil pengujian model 1 mendapatkan nilai akurasi sebesar 98,10%. perhitungan nilai akurasi dapat dilihat pada perhitungan berikut :

$$Accuracy = \frac{TP}{TP+FP+FN} * 100\%$$

$$Accuracy = \frac{309}{(102 + 105+102+3+3)} * 100\%$$

$$Accuracy = \frac{309}{315} * 100\%$$

$$Accuracy = 0,9810 * 100\%$$

$$Accuracy = 98,10 \%$$

3.5.2. Hasil Pengujian dan Evaluasi Model 2

Dari 315 model 2 berhasil mengklasifikasikan sebanyak 311 sampel dengan benar dan 4 sampel terklasifikasi kedalam kelas yang salah. Rincian lebih jelas terkait pengujian model 2 dapat dilihat pada Tabel 7 berikut.

Tabel 7. Confusion Matrix Model 2

		Actual		
		Nantu	Palapi	Uru
Predicted	Nantu	104	0	1
	Palapi	1	104	0
	Uru	3	0	102

Hasil pengujian model 2 mendapatkan nilai akurasi sebesar 98,41%. perhitungan nilai akurasi dapat dilihat pada perhitungan berikut :

$$Accuracy = \frac{TP}{TP+FP+FN} * 100\%$$

$$Accuracy = \frac{311}{(104 + 104+102+1+1+3)} * 100\%$$

$$Accuracy = \frac{311}{315} * 100\%$$

$$Accuracy = 0,9841 * 100\%$$

$$Accuracy = 98,41 \%$$

3.5.3. Hasil Pengujian dan Evaluasi Model 3

Dari 315 model 3 berhasil mengklasifikasikan sebanyak 307 sampel dengan benar dan 8 sampel terklasifikasi kedalam kelas yang salah. Rincian lebih jelas terkait pengujian model 3 dapat dilihat pada Tabel 8 berikut.

Tabel 2. Confusion Matrix Model 3

		Actual		
		Nantu	Palapi	Uru
Predicted	Nantu	101	0	4
	Palapi	0	105	0
	Uru	4	0	101

Hasil pengujian model 3 mendapatkan nilai akurasi sebesar 97,46%. perhitungan nilai akurasi dapat dilihat pada perhitungan berikut :

$$Accuracy = \frac{TP}{TP+FP+FN} * 100\%$$

$$Accuracy = \frac{(1021+ 105+101)}{(1021+ 105+101+4+ 4)} * 100\%$$

$$Accuracy = \frac{307}{315} * 100\%$$

$$Accuracy = 0,9746 * 100\%$$

$$Accuracy = 97,46 \%$$

3.5.4. Hasil Pengujian dan Evaluasi Model 4

Dari 315 model 4 berhasil mengklasifikasikan sebanyak 308 sampel dengan benar dan 7 sampel terklasifikasi kedalam kelas yang salah. Rincian lebih jelas terkait pengujian model 4 dapat dilihat pada Tabel 9 berikut.

Tabel 9. Confusion Matrix Model 4

		Actual		
		Nantu	Palapi	Uru
Predicted	Nantu	102	0	3
	Palapi	0	105	0
	Uru	4	0	101

Hasil pengujian model 3 mendapatkan nilai akurasi sebesar 97,78%. perhitungan nilai akurasi dapat dilihat pada perhitungan berikut :

$$Accuracy = \frac{TP}{TP+FP+FN} * 100\%$$

$$Accuracy = \frac{(102+ 105+101)}{(102+ 105+101+3+ 4)} * 100\%$$

$$Accuracy = \frac{308}{315} * 100\%$$

$$Accuracy = 0,9778 * 100\%$$

$$Accuracy = 97,78 \%$$

Untuk menentukan model terbaik dalam penelitian ini, perlu dilakukan perbandingan terhadap hasil pengujian dari empat model yang telah dihasilkan. Model 2 menunjukkan nilai akurasi tertinggi dibandingkan dengan tiga model lainnya, sehingga model 2 dipilih sebagai model terbaik [25]. Berikut adalah tabel perbandingan hasil pengujian dari empat model yang dihasilkan pada penelitian ini.

Tabel 10. Variasi Model

Model	Akurasi Pengujian
1	98,10 %
2	98,41 %
3	97,46 %
4	97,78 %

3.6. Penerapan

Pada penelitian ini, Penerapan akan dilakukan menggunakan model dengan tingkat akurasi tertinggi. Model akan diimplementasikan kedalam aplikasi sederhana berbasis *mobile*. Pada aplikasi terdapat 2 pilihan metode input data, yaitu dengan mengambil gambar secara langsung atau melalui gambar yang telah tersimpan dalam perangkat. Pada bagian hasil klasifikasi, tidak hanya menampilkan jenis kayu yang di klasifikasi saja, namun juga ditampilkan nilai

confidence untuk setiap kelas kayu. Tampilan aplikasi dapat dilihat pada Gambar 12, berikut.



Gambar 12. (a) Tampilan Awal Aplikasi, (b) Tampilan Hasil Klasifikasi.

4. DISKUSI

Penggunaan *Convolutional Neural Network* (CNN) dalam klasifikasi jenis kayu berdasarkan citra menghasilkan model klasifikasi dengan tingkat akurasi yang tinggi. Hal ini didukung oleh penelitian sebelumnya yang dilakukan oleh [3].

Penelitian ini menggunakan 1269 data latih dan 315 data uji, yang lebih banyak dibandingkan dengan penelitian sebelumnya yang hanya menggunakan 940 data latih dan 100 data uji. Jumlah data yang lebih besar pada penelitian ini memungkinkan model untuk belajar dengan lebih baik dan menghasilkan representasi yang lebih akurat dari data [26].

Lama pelatihan juga menjadi faktor yang signifikan dalam kedua penelitian ini. Penelitian ini melakukan pelatihan selama 100 *epoch*, sementara penelitian sebelumnya memerlukan 600 epoch untuk mencapai akurasi pelatihan 87,50%. Hal ini menunjukkan bahwa model dalam penelitian ini lebih efisien dalam belajar dari data, mungkin karena arsitektur model yang lebih baik atau teknik pelatihan yang lebih efektif.

Akurasi pengujian penelitian sebelumnya mencapai 95,00%, akurasi pengujian penelitian ini yang mencapai 98,41% menunjukkan bahwa model yang digunakan dalam penelitian ini lebih mampu dalam generalisasi terhadap data yang belum pernah dilihat [25].

Penelitian ini menunjukkan keunggulan dibandingkan penelitian sebelumnya, dengan memanfaatkan dataset yang lebih besar, waktu pelatihan yang lebih singkat, serta menghasilkan akurasi yang lebih tinggi baik pada fase pelatihan maupun pengujian. Temuan ini mengindikasikan adanya peningkatan yang signifikan dalam hal efisiensi dan akurasi model.

5. KESIMPULAN

Penelitian ini menunjukkan potensi besar arsitektur VGG16 dalam klasifikasi jenis kayu berdasarkan citra. Penelitian ini menguji empat model yang berbeda dalam hal pembagian data dan pemilihan metode optimisasi. Hasil penelitian menunjukkan bahwa setiap model menghasilkan akurasi pelatihan dan pengujian yang bervariasi. Model 1, dengan pembagian data 70:30 dan menggunakan optimizer Adam, mencapai akurasi pengujian sebesar 98,10% dan akurasi pelatihan 96,68%. Sementara itu, Model 2, yang juga menerapkan pembagian data 70:30 tetapi dengan optimizer Adamax, menunjukkan performa yang lebih baik dengan akurasi pengujian tertinggi sebesar 98,41% dan akurasi pelatihan 99,47%.

Model 3 dan Model 4, yang menggunakan pembagian data 80:20, menunjukkan akurasi pengujian masing-masing sebesar 97,46% dan 97,78%. Meskipun Model 4, yang juga menggunakan optimizer Adamax, menghasilkan akurasi pelatihan sebesar 99,59%, model ini tidak dapat mengungguli Model 2 dalam hal akurasi pengujian.

Secara keseluruhan, Model 2 terbukti sebagai model terbaik dalam penelitian ini, menegaskan bahwa kombinasi pembagian data 70:30 dan penggunaan optimizer Adamax sangat efektif dalam meningkatkan akurasi klasifikasi jenis kayu.

Hasil penelitian ini memiliki implikasi yang signifikan, baik untuk penelitian lebih lanjut maupun untuk aplikasi industri. Dengan tingkat akurasi klasifikasi yang tinggi, teknologi ini dapat diadopsi dalam industri pengolahan kayu untuk meningkatkan efisiensi dalam identifikasi jenis kayu. Hal ini akan berdampak positif pada kualitas produk serta penghematan biaya. Selain itu, temuan ini membuka peluang untuk penelitian lanjutan dalam pengembangan model klasifikasi yang lebih canggih dan eksplorasi berbagai arsitektur CNN yang dapat menawarkan keunggulan dalam hal akurasi dan kecepatan. Penelitian di masa depan juga disarankan untuk mempertimbangkan penerapan teknik augmentasi data tambahan guna memperkaya dataset yang ada dan meningkatkan ketahanan model terhadap variasi dalam citra kayu, serta menambahkan ragam jenis kayu lainnya untuk memperkaya *dataset*.

DAFTAR PUSTAKA

- [1] 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.
- [2] 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.
- [3] 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.
- [4] H. Aszahrah, S. Anraeni, and H. Darwis, "Penerapan Metode K-Nearest Neighbour untuk Mengidentifikasi Jenis Kayu Sebagai Bahan Furniture," *Buletin Sistem Informasi dan Teknologi Islam*, vol. 3, no. 4, pp. 284–292, 2022.
- [5] R. R. Waliyansyah and C. Fitriyah, "Perbandingan Akurasi Klasifikasi Citra Kayu Jati Menggunakan Metode Naive Bayes dan k-Nearest Neighbor (k-NN)," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 5, no. 2, pp. 157–163, 2019.
- [6] 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.
- [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] 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.
- [9] 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.
- [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/jtiik.202184553.
- [14] U. Ungkawa and G. Al Hakim, “Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 3, pp. 731–743, Jul. 2023, doi: 10.26760/elkomika.v11i3.731.
- [15] R. Soekarta, N. Nurdjan, and A. Syah, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN),” *INSECT (Informatics and Security)*, vol. 8, no. 2, pp. 143–151, 2023.
- [16] 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.
- [17] 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.
- [18] 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/jacost.v4i2.486.
- [19] R. A. Tilasefana and R. E. Putra, “View of Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG Net Untuk Pengenalan Cuaca,” *Journal of Informatics and Computer Science*, vol. 5, no. 1, pp. 48–57, 2023.
- [20] Q. Yin, R. Zhang, and X. Shao, “CNN and RNN mixed model for image classification,” *MATEC Web of Conferences*, vol. 277, no. 02001, pp. 1–7, Apr. 2019, doi: 10.1051/mateconf/201927702001.
- [21] T. I. Z. M. Putra, Suprpto, and A. F. Bukhori, “Model Klasifikasi Berbasis Multiclass Classification dengan kombinasi indobert Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia,” *Jurnal Ilmu Siber dan Teknologi Digital*, vol. 1, no. 1, pp. 1–8, 2022, doi: <https://doi.org/10.35912/jisted.v1i1.1509>.
- [22] R. Yotenka and F. F. El Huda, “Implementasi Long Short-Term Memory Pada Harga Saham Perusahaan Perkebunan Di Indonesia,” *UJMC*, vol. 6, no. 1, pp. 9–18, 2020.
- [23] 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.
- [24] A. Paleyes, R. G. Urma, and N. D. Lawrence, “Challenges in Deploying Machine Learning: A Survey of Case Studies,” *ACM Comput Surv*, vol. 55, no. 6, Dec. 2022, doi: 10.1145/3533378.
- [25] J. Feriawan and D. Swanjaya, “Perbandingan Arsitektur Visual Geometry Group dan MobileNet Pada Pengenalan Jenis Kayu,” in *Seminar Nasional Inovasi Teknologi*, UN PGRI Kediri, Jun. 2020.
- [26] A. Peryanto, A. Yudhana, and R. Umar, “Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation,” *Journal of Applied Informatics and Computing (JAIC)*, vol. 4, no. 1, pp. 45–51, Jul. 2020, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>.