

Klasifikasi Rumah Adat di Indonesia Berbasis Citra Menggunakan Convolutional Neural Network

Gita Nadila Berliani*¹, Setio Basuki¹

Universitas Muhammadiyah Malang

gitanadila01@gmail.com *¹, setio_basuki@umm.ac.id¹

Abstrak

Penelitian ini berfokus pada pengembangan model klasifikasi citra rumah adat di Indonesia menggunakan Convolutional Neural Network. Indonesia dikenal memiliki beragam rumah adat yang mencerminkan budaya dan kearifan lokal setiap daerah. Namun, keberagaman ini mulai terancam oleh pengaruh budaya asing dan kurangnya minat generasi muda. Untuk melestarikan dan mempermudah pengenalan rumah adat, penelitian ini memanfaatkan teknologi deep learning dengan model CNN seperti VGG-16, MobileNet, dan Xception. Dalam studi ini menentukan akurasi terbaik dalam mengenali dan mengklasifikasikan berbagai jenis rumah adat. Dataset yang digunakan terdiri dari sepuluh kategori rumah adat, dengan lima kategori tambahan untuk meningkatkan variasi dan representasi data. Hasil penelitian ini menunjukkan peningkatan dalam akurasi klasifikasi hingga 87% setelah dilakukan augmentasi dan hyperparameter tuning pada model MobileNet.

Kata Kunci: *Convolutional Neural Network, Image Classification, Klasifikasi, Deep Learning, Rumah Adat Indonesia*

Abstract

This research focuses on developing an image classification model of traditional houses in Indonesia using Convolutional Neural Network. Indonesia is known to have a variety of traditional houses that reflect the culture and local wisdom of each region. However, this diversity is starting to be threatened by the influence of foreign cultures and the lack of interest of the younger generation. To preserve and facilitate the recognition of traditional houses, this study utilizes deep learning technology with CNN models such as VGG-16, MobileNet, and Xception. This study determines the best accuracy in recognizing and classifying various types of traditional houses. The dataset used consists of ten categories of traditional houses, with five additional categories to increase the variety and representation of the data. The results showed an improvement in classification accuracy of up to 87% after augmentation and hyperparameter tuning on the MobileNet model.

Keywords: *Convolutional Neural Network, Image Classification, Classification, Deep Learning, Indonesian Traditional House*

1. Pendahuluan

Indonesia dikenal sebagai negara dengan keragaman dan kekayaan budaya. Keragaman budaya memberikan makna unik bagi kehidupan suatu bangsa yang harus dilestarikan dan diwariskan kepada generasi berikutnya. Salah satu aspek penting dalam melestarikan warisan budaya adalah Rumah Adat. Rumah adat merupakan bangunan rumah yang mencirikan khas bangunan suatu daerah di Indonesia dengan melambangkan kebudayaan dan karakteristik unik [1]. Keunikan bentuk dan arsitektur yang memiliki nilai kearifan lokal merupakan ciri khas dari rumah adat, jenis, dan keragaman filosofi yang tertanam menjadi bukti kekayaan bangsa Indonesia [2].

Seiring perkembangan zaman telah membawa banyak perubahan, seperti masuknya budaya asing yang dapat melunturkan nilai-nilai budaya di Indonesia [3]. Generasi muda saat ini cenderung kurang tertarik dalam mempelajari budaya tradisional dan lebih memperhatikan budaya asing. Hal ini berdampak pada keberlanjutan dan pemahaman terhadap warisan budaya. Meskipun begitu, tantangan yang dihadapi tidak hanya terbatas pada kurangnya minat, namun juga pada kesulitan dalam mengenali dan memahami rumah adat, khususnya pada ciri arsitektural dan gaya desain yang unik berdasarkan adat istiadat daerah yang memiliki nilai-nilai,

filosofi, fungsi, dan makna [4]. Oleh karena itu, diperlukan adanya teknologi digital seperti klasifikasi citra rumah adat agar dapat membantu membedakan jenis rumah adat di Indonesia.

Klasifikasi citra merupakan proses pengelompokan objek pada suatu citra ke dalam sejumlah kelas [5]. Klasifikasi citra dapat dilakukan melalui beberapa cara dengan menggunakan model Machine Learning dan Deep Learning. Pembangunan model Machine Learning melibatkan ekstraksi fitur dari data pelatihan dan penerapan algoritma pembelajaran khusus untuk mengklasifikasikan citra. Teknologi Deep Learning, khususnya *Convolutional Neural Network* (CNN) menjadi salah satu metode terkemuka untuk klasifikasi citra dengan performa yang signifikan, terutama dalam mengklasifikasikan data citra secara real-time [6].

Saat ini, deep learning digunakan untuk memproses pelatihan khususnya di bidang citra dengan menggunakan transfer learning. Transfer Learning merupakan teknik yang memanfaatkan model yang telah dilatih sebelumnya untuk mengklasifikasi data yang baru, sehingga tidak harus menjalankan data training dari awal dan dilakukan penyesuaian akhir dari model [7].

Penelitian ini relevan dengan penelitian yang dilakukan oleh Firmansah, et al (2023) mengklasifikasi citra rumah adat Indonesia menggunakan arsitektur CNN dengan transfer learning seperti *MobileNetV2*, *VGG16*, dan *Xception* [8]. Penelitian serupa dilakukan oleh Limas, et al (2017) mengklasifikasi citra *Architecture Heritage Elements* (AHE datasets) menggunakan arsitektur CNN dengan menerapkan transfer learning *InceptionV3* [9]. Pengenalan menggunakan transfer learning dapat membantu mengklasifikasi citra untuk meningkatkan akurasi klasifikasi.

Beberapa penelitian tentang klasifikasi rumah adat pernah dilakukan oleh Nahak, et al (2023) mengklasifikasi jenis rumah adat Malaka dengan menggunakan arsitektur CNN. Penelitian ini diimplementasikan pada dua dataset, yaitu rumah adat Kolibein dan Laleik [10]. Penelitian lain dilakukan oleh Riti, et al (2023) mengklasifikasi jenis rumah adat Nusa Tenggara Timur (NTT) menggunakan arsitektur CNN dan *Capsule Network* (*CapsNet*) yang akan dilakukan perbandingan dari kedua kinerja model [11].

Dalam penelitian ini, dataset yang digunakan terdiri dari 10 kategori. Lima kategori pertama diambil dari penelitian Firmansyah (2023). Selanjutnya, lima kategori tambahan diusulkan dalam penelitian ini sebagai penambahan dataset.

Tabel 1. Jumlah kategori dataset rumah adat yang digunakan oleh Firmansah et al (a), usulan penambahan kategori rumah adat di penelitian ini (b)

Rumah Adat	Jumlah	Rumah Adat	Jumlah
Joglo	720	Kebaya	100
Gadang	962	Angkul – Angkul	100
Tongkonan	1000	Tanean Lanjhang	100
Panjang	624	Rumoh Aceh	100
Honai	613	Mbaru Niang	100

(a)

(b)

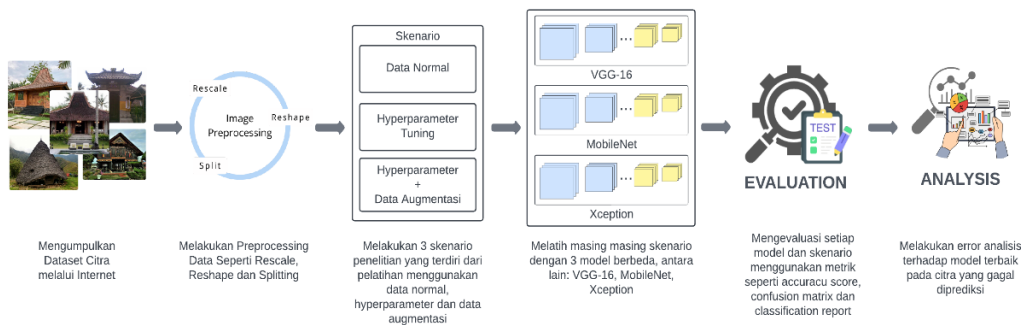
Pada Tabel 1(a) menunjukkan bahwa hasil penelitian yang dilakukan oleh Firmansah, et al (2023) berkisar di atas angka 600. Namun, pada dataset tersebut masih bersifat monoton dan kategori yang tidak mewakili suku dengan jumlah penduduk terbanyak, serta beberapa citra didalamnya memiliki tingkat redundansi yang tinggi dari sisi visual. Sehingga pada penelitian ini mengusul kategori baru untuk ditambahkan agar meningkatkan variasi dataset seperti pada Tabel 1(b).

Dengan demikian, penelitian ini berkontribusi untuk mengatasi kekurangan pada penelitian terdahulu dengan cara menambah kategori baru untuk meningkatkan variasi dataset. Sehingga, penelitian ini dapat mengembangkan sistem klasifikasi citra untuk mengenali lebih banyak jenis rumah adat di Indonesia.

2. Metode Penelitian

2.1 Skema Eksperimen

Pada penelitian ini telah merancang skema eksperimen yang akan ditetapkan untuk mendapatkan hasil evaluasi dari tiap model yang telah ditentukan, seperti pada Gambar 1.



Gambar 1. Rancangan Eksperimen Penelitian

2.2 Dataset

Dalam penelitian ini, dataset citra rumah adat diperoleh dari dua sumber utama. Pertama, dataset dikumpulkan dari platform Kaggle dan telah diteliti sebelumnya dalam penelitian yang berjudul "Transfer Learning Implementation On Image Recognition Of Indonesian Traditional Houses" [8]. Dataset ini terdiri dari lima jenis rumah adat, yaitu rumah joglo, gadang, tongkonan, panjang, dan honai, dengan masing-masing kategori memiliki 100 citra. Selain itu, dataset tambahan diperoleh melalui proses pengumpulan dan penyeleksian dari internet secara manual. Dataset tambahan terdiri dari lima kategori rumah adat dengan jumlah citra yang sama, yaitu 100 citra untuk setiap kategori. Kategori yang digunakan dalam dataset tambahan meliputi kebaya, angkul-angkul, tanean lanjhang, rumoh Aceh, dan mbaru niang. Setelah pengumpulan data tiap kategori dilakukan proses augmentasi untuk meningkatkan jumlah data. Berikut adalah rincian jumlah citra setelah augmentasi untuk setiap kategori.

Tabel 2. Jumlah Kategori Dataset Rumah Adat yang Digunakan Setelah Dilakukan Proses Augmentasi

Rumah Adat	Jumlah	Rumah Adat	Jumlah
Joglo	672	Kebaya	660
Gadang	660	Angkul – Angkul	660
Tongkonan	642	Tanean Lanjhang	642
Panjang	660	Rumoh Aceh	660
Honai	648	Mbaru Niang	660

(a)

(b)

Data yang didapat pada penelitian ini terdiri dari 6564 data citra. Contoh citra rumah adat yang digunakan pada penelitian ini bisa dilihat pada Gambar 2.



Gambar 2. Citra Rumah Adat di Indonesia

2.3 Preprocessing

Sebelum melatih data citra rumah adat, tahap preprocessing dilakukan guna memperbaiki kualitas serta memperbanyak variasi data yang adat. Dalam penelitian ini, beberapa tahap

preprocessing diterapkan untuk meningkatkan kualitas dataset agar sesuai dengan model yang akan digunakan. Berikut tahapan yang dilakukan untuk preprocessing:

a) Rescale

Proses rescaling dilakukan untuk menormalisasi nilai piksel dalam citra. Dengan mengubah rentang nilai piksel dari 0 hingga 255 menjadi rentang 0 hingga 1.

b) Reshape


Banyak model jaringan saraf konvolusi (CNN) yang umum digunakan, seperti model yang digunakan pada penelitian ini mengharapkan input dengan ukuran tertentu. Dengan mengubah dimensi citra menjadi ukuran yang diharapkan oleh model (224x224 piksel), kita memastikan bahwa citra-citra tersebut cocok dengan struktur input model yang ditentukan, sehingga memungkinkan pelatihan model yang lancar.

c) Data Augmentation

Teknik data augmentation diterapkan untuk model *deep learning* dapat belajar dan mengenali dari berbagai citra yang berbeda-beda sekaligus bisa dimanfaatkan untuk memperbanyak data [8]. Teknik ini juga membantu mencegah overfitting dengan memperkenalkan keragaman tambahan ke dalam dataset [12]. Teknik yang digunakan pada augmentasi data adalah seperti memperbesar dan memperkecil (zoom-in/out), membalik (flip), memutar (rotate), menggeser (shear) dan blur.

d) Splitting Data

Setelah proses augmentasi data, langkah selanjutnya adalah membagi dataset menjadi beberapa bagian yang berbeda dalam membangun model pada machine learning menjadi setidaknya data latih (*train*) dan uji (*test*) [13]. Pada penelitian ini data dibagi menjadi 3 bagian yaitu data train, validasi, dan test. Berikut merupakan contoh data citra yang telah di augmentasi.



Gambar 3. Data Citra setelah dilakukan Augmentasi Data

2.4 Klasifikasi

Setelah melewati tahap preprocessing, langkah berikutnya adalah melatih dataset pada model klasifikasi. Total 3 model akan digunakan untuk melatihnya, antara lain adalah VGG-16, MobileNet, dan Xception. Top layer atau Fully Connected Layer (FCL) akan disesuaikan dengan kebutuhan klasifikasi yang spesifik untuk dataset yang digunakan. Pada penelitian ini, beberapa layer ditambahkan seperti Global Average Pooling, 1 Dense, 1 Dropout, dan 1 Dense sebagai output pada FCL.

2.5 Evaluasi

Pada penelitian ini dilakukan analisis terhadap kinerja model yang telah ditentukan. Proses evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu menghasilkan hasil prediksi yang akurat dari beberapa metrik evaluasi seperti accuracy score, confusion matrix, dan classification report. Accuracy score digunakan untuk mengukur seberapa baik model dapat mengklasifikasikan dengan benar dari hasil training yang dilakukan. Confusion matrix mampu mempresentasikan prediksi dan kondisi sebenarnya (aktual). Pada penilaian menggunakan confusion matrix memiliki beberapa parameter pengukuran yang digunakan, diantaranya True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN). Classification Report melibatkan nilai presisi (*precision*), recall, dan F1-Score yang dihitung menggunakan rumus tertentu. Berikut rumus matematika dari confusion matrix [14].

a. *Accuracy* pada Persamaan 1 adalah pembagian jumlah prediksi benar terhadap jumlah total prediksi.

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \quad (1)$$

- b. *Precision* pada Persamaan 2 adalah rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif.

$$\text{Presisi} = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

- c. *Recall* pada Persamaan 3 adalah rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif.

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

- d. *F1-Score* pada Persamaan 4 adalah perbandingan rata-rata presisi dan recall yang dibobotkan.



$$\text{F1-Score} = 2 \times \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \times 100\% \quad (4)$$

3. Hasil Penelitian dan Pembahasan


3.1 Skenario Eksperimen

3.1.1 Skenario Pengujian 1


Pada skenario ini dataset dilatih menggunakan ke-tiga model pretrained dengan konfigurasi parameter yang sama untuk setiap modelnya. Model yang digunakan dalam skenario ini menggunakan arsitektur dengan satu lapisan dense yang memiliki 512 neuron dan learning rate yang diatur sebesar 0.001. Lalu model dilatih sebanyak 100 epoch dengan menerapkan fungsi *early stop* untuk menghentikan proses pelatihan jika tidak ada perkembangan selama 20 epoch berturut-turut serta mencegah terjadinya overfitting.



(a)



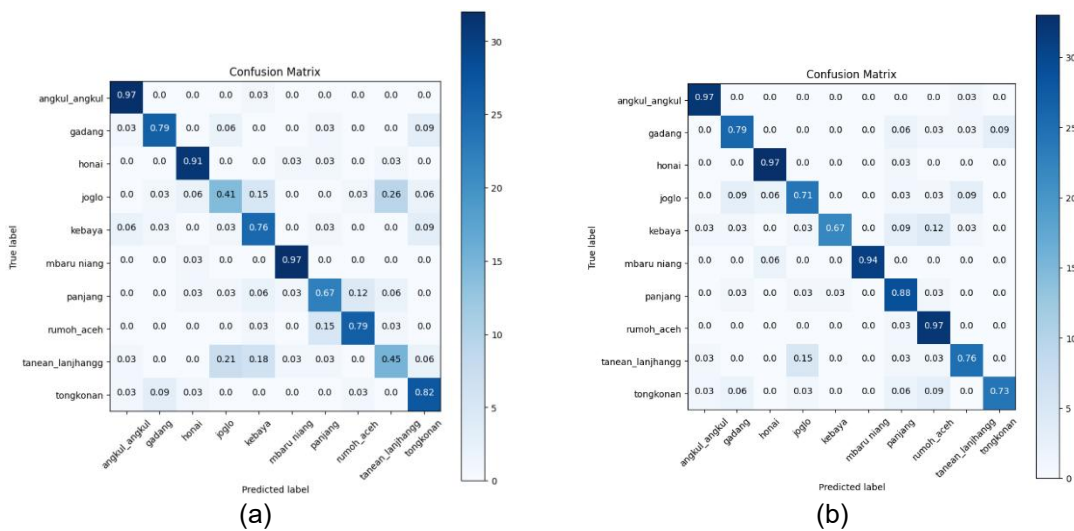
(b)




(c)

Gambar 3. Grafik Learning Curve Model (a) VGG-16, (b) MobileNet, dan (c) Xception Skenario 1

Learning curve dari ketiga model pretrained (VGG-16, MobileNet, dan Xception) menggambarkan akurasi dan loss pada data train dan validation selama beberapa epoch. Meskipun semua model dilatih selama 100 epoch, beberapa model berhenti lebih awal karena menggunakan fungsi early stop dengan patience selama 20 epoch untuk menghindari overfitting. Model VGG-16 (Gambar 3a) menunjukkan peningkatan akurasi train yang stabil hingga sekitar 0.8 pada epoch ke-50, namun akurasi validation cenderung berfluktuasi di sekitar 0.6-0.7, dengan loss train menurun hingga di bawah 0.5 dan loss validation tetap berfluktuasi sekitar 0.75-1.0. Model MobileNet (Gambar 3b) menunjukkan performa yang lebih seimbang dengan akurasi train meningkat hingga sekitar 0.9 pada epoch ke-25, dan akurasi validation stabil di sekitar 0.7-0.75, loss train menurun hingga sekitar 0.25 dan loss validation berfluktuasi di sekitar 0.75-1.0. Model Xception (Gambar 3c) menunjukkan akurasi train yang sangat tinggi, mencapai sekitar 0.9 pada epoch ke-50, namun akurasi validation hanya sekitar 0.7 dan cenderung lebih berfluktuasi loss train menurun secara signifikan hingga sekitar 0.25, tetapi loss validation tetap tidak stabil di sekitar 1.0. Hal ini mengindikasikan bahwa meskipun ketiga model menunjukkan performa train yang kuat, performa validation mereka mengungkapkan tingkat overfitting yang tinggi, dengan model Xception menunjukkan ketidakstabilan dan overfitting tertinggi di antara ketiganya.





(c)
Gambar 4. Confusion Matrix (a) VGG-16, (b) MobileNet dan (c) Xception Skenario 1


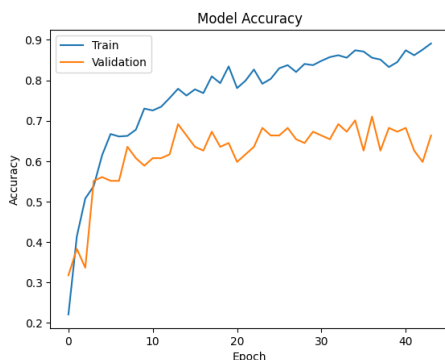
Hasil dari confusion matrix pada Gambar 4 menunjukkan bahwa model dapat mengenali rumah adat dengan baik. Namun, terdapat masalah pada beberapa kategori yang diprediksi oleh model. Kategori joglo dan tanean lanjhang menunjukkan hasil prediksi yang rendah untuk setiap model. Di sisi lain, kategori gadang dan tongkonan saling memprediksi satu sama lain. Dari confusion matrix model VGG-16 (Gambar 4a) memprediksi kategori joglo sebagai tanean lanjhang dan sebaliknya sebesar 26% dan 21%, MobileNet (Gambar 4b) sebesar 9% dan 15%, Xception (Gambar 4c) sebesar 21% dan 12%. Lalu pada model Xception terdapat missprediction untuk kategori gadang sebagai tongkonan sebesar 24%.

3.1.2 Skenario Pengujian 2

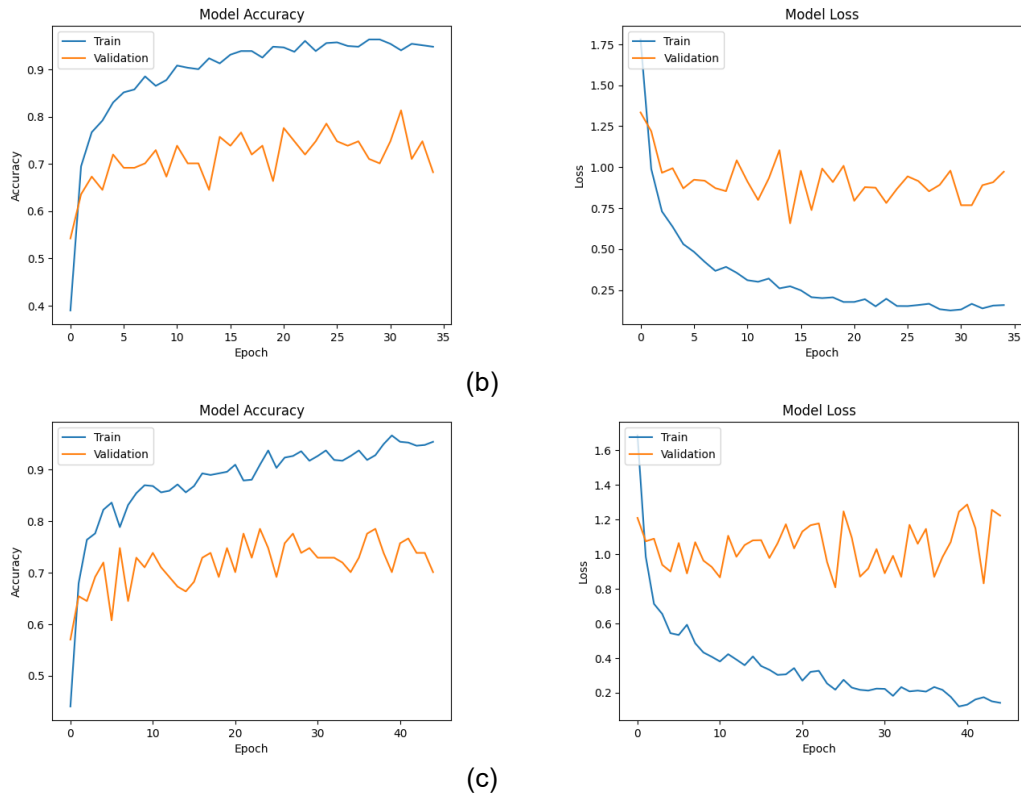
Pada skenario ini penerapan teknik hyperparameter tuning dilakukan. Metode random search digunakan untuk mencari parameter yang optimal dari setiap model pretrained yang digunakan. Fokus optimasi kali ini adalah pada dua parameter utama: jumlah unit pada layer dense (dengan rentang 128 hingga 512 unit) dan learning rate (dengan rentang 1×10^{-4} hingga 1×10^{-2}). Proses random search dilakukan dengan total 10 percobaan untuk setiap model, pelatihan model sebanyak 50 epoch dan menggunakan fungsi early stopping yang memiliki patience 5 epoch. Pencarian parameter untuk setiap model, didapatkan parameter yang optimal seperti pada Tabel 3.

Tabel 3. Hyperparameter Optimal dari Setiap Model

Model	Dense Units	Learning Rate
VGG-16	448	0.208441648380325
MobileNet	384	0.000380014015172
Xception	384	0.000841846864318

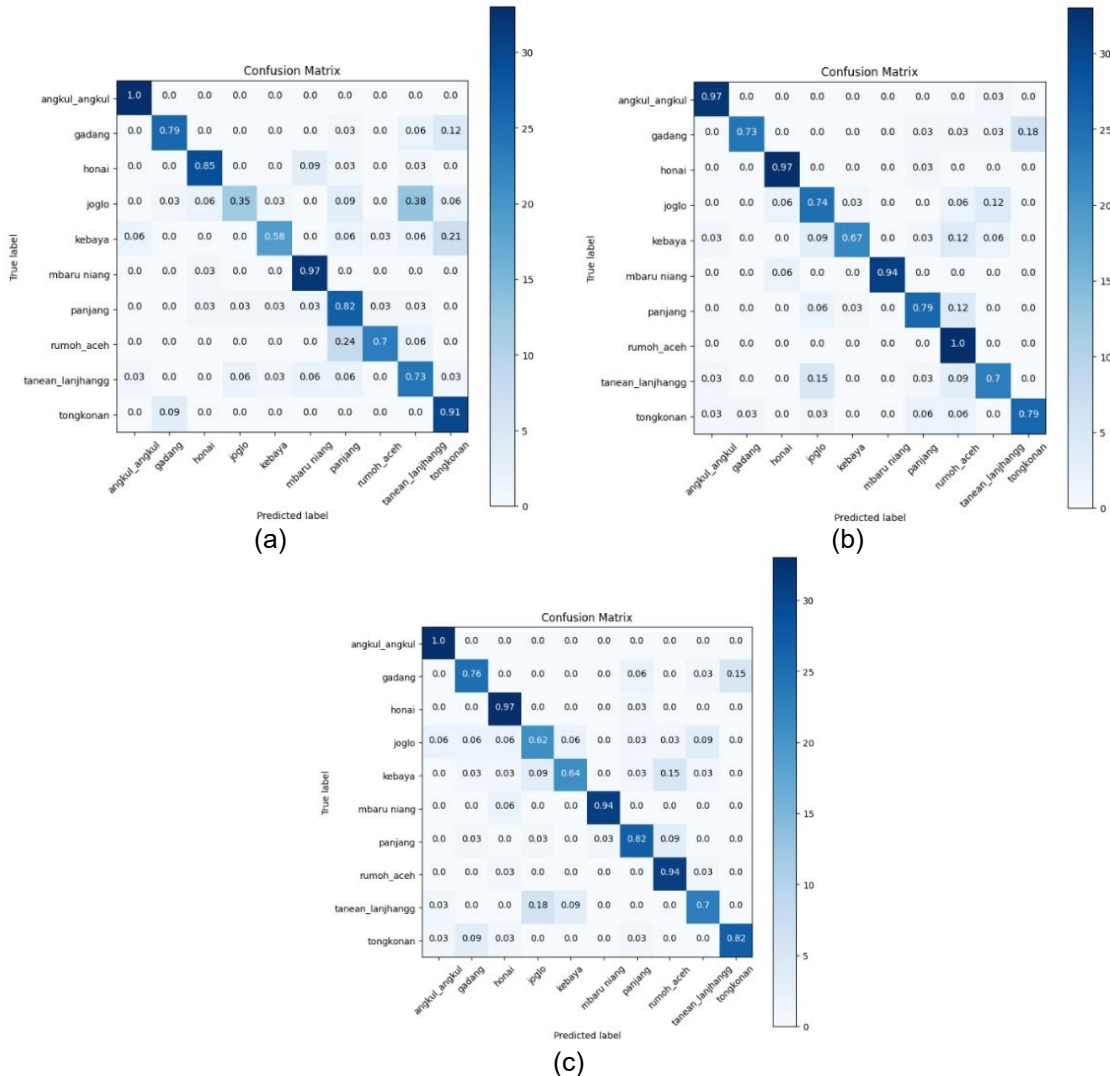


(a)



Gambar 5. Grafik Learning Curve Model (a) VGG-16, (b) MobileNet, dan (c) Xception Skenario 2

Gambar 5 merupakan hasil pengamatan terhadap learning curve dari tiga model pretrained (VGG-16, MobileNet, dan Xception) setelah dilakukan hyperparameter tuning (HT). Pada model VGG-16 dengan HT, akurasi training mencapai sekitar 90% pada akhir epoch, sedangkan akurasi validation hanya sekitar 70%, menunjukkan adanya overfitting serta terjadi fluktuasi pada seluruh model. Nilai loss pada training terus menurun hingga sekitar 0.5, sementara loss validation tetap sekitar 1.0. Pada model MobileNet dengan HT, akurasi training mencapai sekitar 95%, namun akurasi validation berfluktuasi di sekitar 75%, juga menunjukkan tanda overfitting. Loss pelatihan turun hingga sekitar 0.25, sedangkan loss validasi tetap berada di kisaran 1.0. Terakhir, model Xception dengan HT menunjukkan akurasi training mendekati 95%, namun akurasi validation tetap berfluktuasi di sekitar 75%. Loss training turun hingga sekitar 0.2, sementara loss validation tetap stabil di sekitar 1.0. Secara keseluruhan, ketiga model menunjukkan pola overfitting yang serupa, dengan akurasi pelatihan yang tinggi namun akurasi validasi yang jauh lebih rendah dan loss validasi yang tidak menurun secara signifikan.

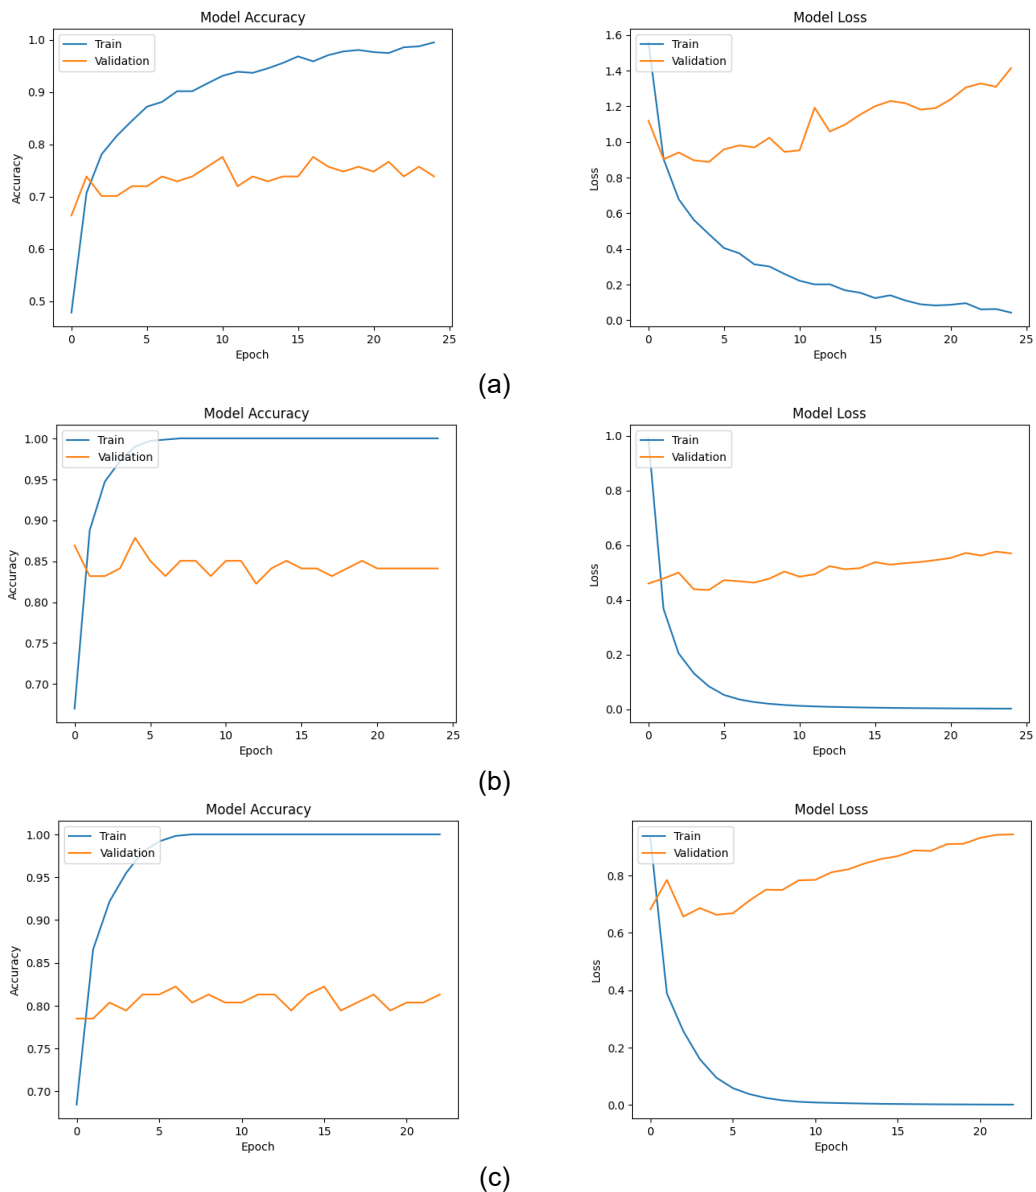


Gambar 6. Confusion Matrix (a) VGG-16, (b) MobileNet dan (c) Xception skenario 2

Untuk confusion matrix pada skenario ini dapat dilihat pada Gambar 6. Secara keseluruhan model MobileNet masih memiliki tingkat loss predict yang lebih kecil dibandingkan dengan model lainnya. Lalu tingkat miss prediction untuk kategori seperti tanean lanjhang dan joglo juga menurun, kecuali pada model VGG-16 pada (Gambar 6a) memprediksi joglo sebagai tanean lanjhang dan kebaya sebagai tongkonan yang meningkat menjadi 38% dan 21%.

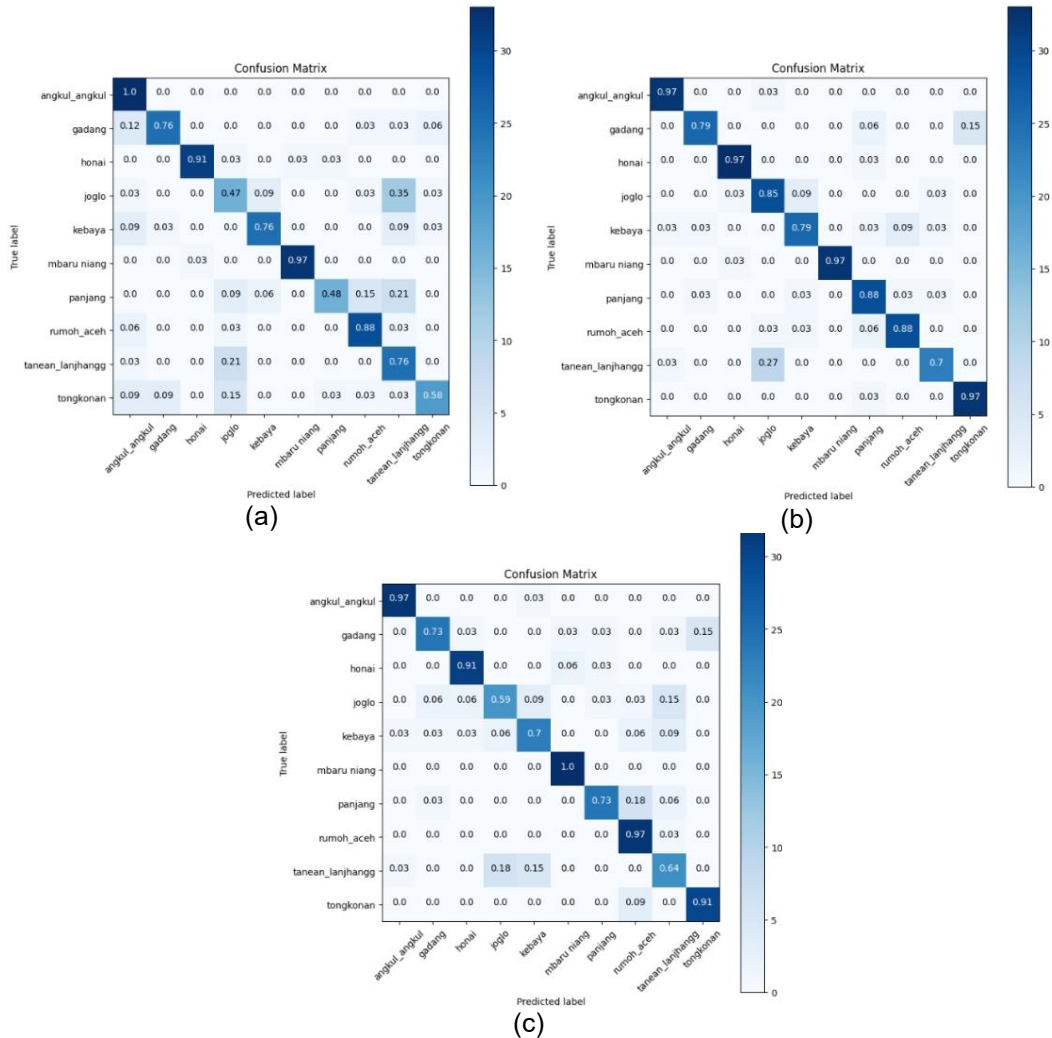
3.1.3 Skenario Pengujian 3

Pada skenario ini, dilakukan penambahan secara sintetik dengan cara Augmentasi data untuk meningkatkan variasi data. Teknik augmentasi yang digunakan meliputi Flip, Rotate, Shear, Blur, dan Sharpen. Selain implementasi augmentasi data, penggunaan parameter yang telah dilakukan pada **Skenario Pengujian 2** juga digunakan. Jumlah data train setelah dilakukan augmentasi pada penelitian ini adalah sebanyak 3.257 citra.



Gambar 7. Grafik Learning Curve Model (a) VGG-16, (b) MobileNet, dan (c) Xception Skenario 3

Dari grafik learning curve pada Gambar 7 menampilkan bahwa ke-tiga model mengalami overfitting, hal ini ditandai pada akurasi train meningkat menjadi 1.0. Overfitting ini terjadi dikarenakan data train yang telah di augmentasi. Meskipun augmentasi data meningkatkan variasi dan jumlah data training, model cenderung belajar terlalu detail dari data augmented sehingga kurang mampu generalisasi pada data validation. Hal serupa juga terjadi pada tingkat loss pada data training. Loss training terus menurun menjadi 0, sedangkan loss validation konstan di angka 1.0-0.5 untuk semua model.



Gambar 8. Confusion Matrix (a) VGG-16, (b) MobileNet dan (c) Xception skenario 3

Untuk confusion matrix pada skenario ini dapat dilihat pada Gambar 8. Secara keseluruhan model VGG-16 masih memiliki tingkat loss predict paling tinggi diantara lainnya. Dapat dilihat pada (Gambar 8a) model VGG-16 memprediksi kategori joglo sebagai kategori lain sebesar 9% untuk kebaya dan 35% untuk tanean lanjhang. Begitu juga, ketika model memprediksi kategori tanean lanjhang, model memprediksi kategori lain sebesar 21% sebagai joglo.

3.2 Hasil Kinerja Model dan Analisis Error

Dari segi performa model yang diperlihatkan pada learning curve Gambar 4, Gambar 5 dan Gambar 7 terlihat bahwa hasil yang didapatkan untuk setiap skenario berbeda-beda. Pada Skenario 1 seluruh model terlihat fluktuatif namun minimnya muncul tanda overfitting, lalu pada Skenario 2 gap antara akurasi train dan validasi semakin besar, dan tetap mengalami fluktuasi, dan terakhir pada Skenario 3 terlihat bahwa fluktuasinya sangat minim dan gap antara akurasi training dan validasi cukup besar.

Tabel 4. Classification Report Skenario 1

Model	Accuracy	Loss	Precision	Recall	F1-Score
VGG-16	0.753	0.719	0.75	0.75	0.75
MobileNet	0.837	0.526	0.85	0.84	0.84
Xception	0.774	0.689	0.78	0.77	0.77

Tabel 5. Classification Report Skenario 2

Model	Accuracy	Loss	Precision	Recall	F1-Score
VGG-16	0.768	0.769	0.79	0.77	0.76
MobileNet	0.828	0.543	0.84	0.83	0.83
Xception	0.819	0.725	0.81	0.81	0.81

Tabel 6. Classification Report Skenario 3

Model	Accuracy	Loss	Precision	Recall	F1-Score
VGG-16	0.757	0.686	0.78	0.76	0.75
MobileNet	0.876	0.472	0.88	0.88	0.88
Xception	0.813	0.642	0.81	0.81	0.81

Dari ketiga model dan skenario yang dilakukan, terlihat bahwa MobileNet mengungguli dari seluruh model dengan konsisten. Dalam semua skenario, MobileNet menunjukkan akurasi tertinggi, diikuti oleh nilai precision, recall, dan F1-Score dengan sangat baik dibandingkan model VGG-16 dan Xception. Namun, penting untuk melakukan analisis error pada setiap prediksi loss untuk memahami lebih dalam kelemahan dan area yang perlu diperbaiki pada masing-masing model.

Tabel 7. Frekuensi Kesalahan Prediksi Model Terbaik

No	Kategori	Frekuensi kesalahan	Keterangan
1.	Angkul-angkul	3%	Diprediksi Joglo = 1
2.	Gadang	21%	Diprediksi Panjang = 2, Tongkonan = 5
3.	Honai	3%	Diprediksi Panjang = 1
4.	Joglo	15%	Diprediksi Honai = 1, Kebaya = 3 , Tanean Lanjhang = 1
5.	Kebaya	21%	Diprediksi Angkul-angkul = 1, Gadang = 1, Panjang 1, Rumoh Aceh = 3 , Tanean Lanjhang = 1
6.	Mbaru Niang	3%	Diprediksi Honai = 1
7.	Panjang	12%	Diprediksi Gadang = 1, Kebaya = 1, Rumoh Aceh = 1, Tanean Lanjhang = 1
8.	Rumoh Aceh	12%	Diprediksi Joglo = 1, Kebaya = 1, Panjang = 2
9.	Tanean Lanjhang	30%	Diprediksi Angkul-angkul = 1, Joglo = 9
10	Tongkonan	3%	Diprediksi Panjang = 1

3.3 Analisis Hasil Skenario

Pada analisis ini dilakukan perbandingan hasil pengujian menggunakan model MobileNet dengan hasil replikasi dari penelitian sebelumnya. Hal ini dilakukan untuk mengetahui performa model berdasarkan penggunaan dataset yang digunakan pada penelitian ini dengan dataset yang digunakan pada penelitian sebelumnya. Berikut merupakan perbandingan hasil replikasi pengujian model dari peneliti sebelumnya dengan penelitian saat ini.

Tabel 8. Perbandingan Hasil Pengujian Model MobileNet

Penelitian	Jumlah Kategori	Accuracy
Firmansyah, et al (2023)	5 Class, per class terdapat Joglo, Gadang, Tongkonan, Panjang, dan Honai	0.94
Penelitian ini	10 Class, per class terdapat Joglo, Gadang, Tongkonan, Panjang, Honai, Kebaya, Angkul – Angkul, Tanean Lanjhang, Rumoh Aceh dan Mbaru Niang	0.84

Berdasarkan Tabel 8 merupakan perbandingan hasil klasifikasi menggunakan model MobileNet pada penelitian ini dengan penelitian sebelumnya. Pada penelitian ini, kinerja terbaik model prediksi mencapai akurasi 84% pada skenario ketiga. Skenario tersebut menggabungkan

hyper-parameter optimization dengan data augmentasi. Hasil yang dicapai dinilai kompetitif dibandingkan dengan penelitian sebelumnya yang mencapai kinerja akurasi 94% karena beberapa alasan sebagai berikut:

- 1) Penelitian yang dilakukan oleh Firmansyah, et al (2023) hanya menggunakan 5 class/label.
- 2) Dataset yang digunakan memiliki potensi redundansi yang tinggi.
- 3) Kategori rumah adat yang digunakan terlalu sedikit jika mempertimbangkan jumlah suku dengan populasi yang besar di Indonesia.
- 4) Penelitian sebelumnya secara transparan memberikan learning curve, sehingga tidak bisa diketahui apakah model mengalami overfitting atau tidak.
- 5) Kinerja dari peneliti sebelumnya tidak menggunakan data testing melainkan menggunakan data validation selama proses training.

4. Kesimpulan

Pada penelitian ini, mengembangkan model klasifikasi citra rumah adat di Indonesia dengan menambahkan kategori baru pada dataset yang diharapkan dapat meningkatkan variasi dan representasi rumah adat yang lebih luas. Penelitian ini dilakukan proses preprocessing dan pelatihan model menggunakan Convolutional Neural Network seperti model VGG-16, MobileNet, dan Xception. Setelah dilakukan beberapa skenario pengujian, model MobileNet menunjukkan hasil akurasi tertinggi dengan proses augmentasi data dan hyperparameter optimization sebesar 87%. Hal ini menunjukkan bahwa optimalisasi model dapat memberikan hasil yang signifikan dalam klasifikasi citra rumah adat. Meskipun hasil analisis ini lebih rendah dibandingkan dengan peneliti sebelumnya yang mencapai 94%, capaian ini tetap signifikan dengan menggunakan dataset yang lebih banyak kategori dan potensi redundansi dalam dataset sebelumnya menjadi penyebab perbedaan ini.

Referensi

- [1] T. Abdulghani and B. P. Sati, "Pengenalan Rumah Adat Indonesia Menggunakan Teknologi Augmented Reality Dengan Metode Marker Based Tracking Sebagai Media Pembelajaran," *Media J. Inform.*, vol. 11, no. 1, p. 43, 2020, doi: 10.35194/mji.v11i1.770.
- [2] I. Poerwaningtias and N. K. Suwanto, *Rumah Adat Nusantara*, 1st ed., no. November 2018, Jakarta: Badan Pengembangan dan Pembinaan Bahasa, 2017. [Online]. Available: 1.
- [3] Defriani, M., & Irsan Jaelani, "Recognition of Regional Traditional House in Indonesia Using Convolutional Neural Network (CNN) Method," *Journal of Computer Networks, Architecture and High Performance Computing*, vol. 4, no. 2, pp. 104-115, 2022, doi: 10.47709/cnahpc.v4i2.1562.
- [4] L. Monica, "Fungsi Dan Makna Ruang Pada Rumah Adat Mbaru Niang Wae Rebo," *Intra*, vol. 3, no. 2, pp. 580-585, 2015.
- [5] John. A. Richards, *Remote Sensing Digital Image Analysis, An Introduction*, Springer-Verlag Berlin Heidelberg, 1986.
- [6] Azis, F. A., Suhaimi, H., & Abas, E., "Waste Classification using Convolutional Neural Network," in *Proceedings of the 2020 2nd International Conference on Information Technology and Computer Communications (ITCC)*, 2020, pp. 9-13.
- [7] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q., "A Comprehensive Survey on Transfer Learning," *Proceedings of the IEEE*, vol. 109, pp. 43-76, 2019.
- [8] Firmansyah, R. A., Santoso, H., & Anwar, A., "Transfer Learning Implementation on Image Recognition of Indonesian Traditional Houses," *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 6, pp. 1469-1478, 2023, doi: 10.52436/1.jutif.2023.4.6.767.
- [9] Llamas, J., Leronés, M., Medina, P., Zalama, E., & Gómez-García-Bermejo, J., "Classification of Architectural Heritage Images Using Deep Learning Techniques," *Applied Sciences*, vol. 7, no. 10, p. 992, 2017, doi: 10.3390/app7100992.
- [10] Nahak, R., Bura, A. U., De Araujo, A. D., Un, F. D., Ladopurab, B. W., Marisa, F., & Maukar, A. L., "Klasifikasi Jenis Rumah Adat Malaka Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Teknologi Dan Manajemen Informatika*, vol. 9, no. 2, pp. 91-98, 2023, doi: 10.26905/jtmi.v9i2.10352.
- [11] Riti, Y. F., Wahyuningsih, Y., Roosandriantini, J., & Siswanto, P. W., "Perbandingan Algoritma Convolutional Neural Network dan Capsule Network Dalam Klasifikasi Jenis Rumah Adat," *Teknika*, vol. 12, no. 3, pp. 243-251, 2023, doi: 10.34148/teknika.v12i3.702.

-
- [12] Aloisius Awang Hariman, Dadang Iskandar Mulyana, & Mesra Betty Yel, "Klasifikasi Jajanan Tradisional Jawa Tengah Dengan Metode Transfer Learning Dan MobileNetV2: Metode Transfer Learning Dan MobileNetV2," *Informasi Interaktif : Jurnal Informatika Dan Teknologi Informasi*, vol. 8, no. 1, 2023. Retrieved from <http://informasiinteraktif.janabadra.ac.id/index.php/jii/article/view/15>.
- [13] C. L. M. Morais, M. C. D. Santos, K. M. G. Lima, and F. L. Martin, "Improving Data Splitting for Classification Applications in Spectrochemical Analyses Employing a Random-Mutation Kennard-Stone Algorithm Approach," *Bioinformatics*, vol. 35, no. 24, pp. 5257–5263, Dec. 2019, doi: 10.1093/bioinformatics/btz421.
- [14] G. Shobha and S. Rangaswamy, *Machine Learning*, 1st ed., vol. 38, Elsevier B.V., 2018, doi: 10.1016/bs.host.2018.07.004.