

KLASIFIKASI GAYA SENI LUKIS MENGGUNAKAN *EFFICIENTNET*

Vilbert Ferdinand Lim, Muhammad Ezar Al Rivan

Informatika, Universitas Multi Data Palembang
Jl. Rajawali, No. 14, Palembang, Sumatera Selatan
vilbertlim22@gmail.com

ABSTRAK

Transformasi digital dalam satu dekade terakhir mendorong digitalisasi besar-besaran koleksi karya seni oleh museum dan galeri di seluruh dunia. Kondisi ini menghasilkan jumlah citra seni digital yang sangat besar sehingga proses kurasi dan klasifikasi secara manual menjadi tidak efisien dan rentan terhadap subjektivitas. Permasalahan tersebut menuntut adanya sistem klasifikasi otomatis yang mampu mengidentifikasi gaya seni lukis secara akurat dan efisien. Penelitian ini bertujuan untuk membangun sistem klasifikasi gaya seni lukis menggunakan arsitektur *EfficientNet* dengan pendekatan *transfer learning* guna memperoleh keseimbangan antara akurasi dan efisiensi komputasi. *Dataset* yang digunakan berjumlah 23.704 citra yang terdiri dari tujuh gaya seni lukis, yaitu *Abstract*, *Expressionism*, *Neoclassicism*, *Primitivism*, *Realism*, *Romanticism*, dan *Symbolism*. Proses pelatihan dilakukan pada varian *EfficientNet-B0* hingga *EfficientNet-B7* selama 20 *epoch* dengan variasi *batch size* 8, 16, dan 32. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score* serta analisis efisiensi komputasi. Hasil penelitian menunjukkan bahwa *EfficientNet-B4* dengan *batch size* 32 memberikan performa terbaik dengan akurasi sebesar 94,93%, sekaligus menunjukkan keseimbangan optimal antara kinerja klasifikasi dan kebutuhan komputasi.

Kata kunci : Klasifikasi Gaya Seni, *EfficientNet*, *Compound Scaling*, *Computer Vision*, *Deep Learning*

1. PENDAHULUAN

Dalam satu dekade terakhir, dunia seni mengalami transformasi digital yang signifikan. Berbagai institusi seperti museum, galeri, dan arsip sejarah berlomba-lomba melakukan digitalisasi koleksi karya seni guna mendukung pelestarian serta meningkatkan aksesibilitas publik. Platform digital seperti *Google Arts & Culture* menyediakan jutaan citra karya seni beresolusi tinggi yang dapat diakses secara luas oleh masyarakat. Fenomena ini menghasilkan pertumbuhan data visual yang sangat besar dan menciptakan apa yang dikenal sebagai “ledakan data” dalam bidang seni rupa [1].

Seni lukis yang sebelumnya hanya dinikmati secara fisik kini juga menjadi objek analisis digital dalam skala besar. Namun, jumlah data yang sangat besar tersebut menimbulkan tantangan baru dalam proses pengelolaan dan pengelompokan karya seni secara efektif.

Proses klasifikasi gaya seni lukis secara tradisional masih banyak dilakukan secara manual oleh pakar seni. Meskipun metode ini dapat memberikan hasil yang akurat, prosesnya membutuhkan waktu yang lama serta sangat dipengaruhi oleh subjektivitas pengamat. Selain itu, pertumbuhan jumlah arsip digital yang sangat cepat membuat metode klasifikasi manual menjadi kurang efisien dan sulit diterapkan pada skala data yang besar [2].

Kompleksitas visual dalam seni lukis juga menambah tingkat kesulitan dalam proses klasifikasi, karena batasan antara satu gaya seni dengan gaya lainnya seringkali tidak jelas dan memiliki kemiripan karakteristik visual [3].

Seiring kemajuan teknologi, pendekatan subjektif ini mulai ditinggalkan menuju metode komputasi yang lebih objektif, konsisten, dan efisien [4].

Dalam konteks *Computer Vision*, kondisi ini dikenal sebagai *intra-class variability* yang tinggi dan *inter-class similarity*, sehingga model harus mampu membedakan fitur visual yang sangat halus seperti tekstur kanvas, komposisi warna, serta teknik sapuan kuas.

Beberapa penelitian sebelumnya menunjukkan hasil yang menjanjikan namun bervariasi.

Penelitian oleh [5] mencapai akurasi rata-rata 88,28% melalui integrasi analisis semantik afektif, sementara penelitian lain oleh [6] memperoleh akurasi 82% menggunakan CNN standar.

Hasil penelitian tersebut menunjukkan bahwa sistem komputasi memiliki potensi untuk membantu proses identifikasi gaya seni lukis. Namun demikian, sebagian besar penelitian masih berfokus pada peningkatan akurasi dengan menggunakan arsitektur jaringan yang sangat dalam dan kompleks seperti *ResNet-50*.

Menurut penelitian oleh [7], model *ResNet-50* memiliki 26 juta parameter dengan kebutuhan komputasi sebesar 4.1 miliar *FLOPs*, sehingga membutuhkan sumber daya komputasi yang cukup besar.

Meskipun performa klasifikasi terus mengalami peningkatan, masih terdapat kesenjangan penelitian terkait efisiensi model yang digunakan. Banyak model State-of-the-Art memiliki jumlah parameter yang sangat besar sehingga proses pelatihan maupun inferensi menjadi lebih lambat serta sulit diterapkan pada perangkat dengan keterbatasan sumber daya.

Oleh karena itu, diperlukan pendekatan yang mampu memberikan keseimbangan antara akurasi klasifikasi yang tinggi dengan efisiensi komputasi yang baik.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun dan mengevaluasi sistem klasifikasi gaya seni lukis otomatis menggunakan arsitektur *EfficientNet*. Untuk mengatasi permasalahan yang ada, penelitian ini mengusulkan penggunaan arsitektur *EfficientNet* yang menerapkan metode *compound scaling* untuk menyeimbangkan kedalaman jaringan, lebar kanal, dan resolusi input secara simultan [8].

Pendekatan ini memungkinkan peningkatan kinerja model tanpa peningkatan biaya komputasi yang signifikan. *EfficientNet* juga memiliki kemampuan dalam menangkap detail visual pada citra beresolusi tinggi, sehingga sangat relevan untuk analisis citra seni lukis yang memiliki karakteristik visual yang kompleks [9].

Dengan memanfaatkan berbagai varian *EfficientNet* dari B0 hingga B7, penelitian ini berupaya mengevaluasi performa model dalam melakukan klasifikasi gaya seni lukis serta menentukan varian yang paling optimal dari sisi akurasi dan efisiensi komputasi.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Pada penelitian sebelumnya yang dilakukan oleh [10] penelitian ini menganalisis kinerja tiga model CNN berbeda yaitu *VGG16*, *ResNet50*, dan *Xception* untuk tugas klasifikasi Media Seni (AMC). Hasil awal menunjukkan akurasi tertinggi yaitu 75% dengan 5 kelas, namun dikarenakan adanya tingkat kesalahan klasifikasi yang tinggi antar kelas penelitian ini melakukan eksperimen lanjutan dengan menghilangkan salah satu kelas yang bermasalah. Hasil akurasi klasifikasi terbaik yang didapatkan yaitu 86%.

Penelitian lain oleh [11] yang mengembangkan sistem pengenalan seniman otomatis menggunakan CNN, dimana dalam penelitiannya ada beberapa kesalahan prediksi cacat yang disebabkan oleh beberapa faktor, termasuk gaya seni yang tumpang tindih, kualitas gambar yang rendah dari sumber data dan ukuran *dataset* yang relatif kecil. Hasil penelitian tersebut mendapatkan akurasi tertinggi pada Model-2 yaitu 89% dan Model-1 mendapatkan akurasi 87%.

2.2. Seni Lukis

Seni lukis merupakan cabang seni rupa murni yang lahir dari gagasan dan imajinasi penciptanya untuk mentransfer pesan atau pengalaman batin secara visual dengan tujuan mempengaruhi persepsi audiens. Seni lukis didefinisikan sebagai aktivitas pengolahan elemen rupa pada bidang dua dimensi yang melibatkan integrasi antara unsur fisik seperti titik, garis, bidang, warna, dan tekstur, serta unsur psikis yang meliputi emosi dan konsep [1].

Proses penciptaan karya lukis tidak sekadar peniruan alam, melainkan melibatkan tahapan eksplorasi, improvisasi, dan pembentukan yang sistematis untuk mencapai kesatuan bentuk dan makna yang harmonis [12].

2.3. Deep Learning


Deep Learning adalah metode *Machine Learning* berbasis *Artificial Neural Networks* (ANN) yang meniru struktur biologis otak manusia [13].

Dengan menggunakan arsitektur jaringan saraf yang berlapis-lapis [14], metode ini memiliki keunggulan dalam mempelajari fitur kompleks dari data mentah secara mendalam [15].

2.4. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf tiruan yang berasal dari konsep *Multi Layer Perceptron* (MLP) dirancang khusus untuk memproses dan mengenali pola pada citra dua dimensi [16].

Melalui lapisan-lapisan yang melakukan konvolusi, *pooling*, serta aktivasi, model ini mampu mempelajari fitur visual seperti bentuk dan tekstur secara mandiri. Susunan lapisan dari CNN ditampilkan pada Gambar 1.



Gambar 1. Arsitektur CNN [17]

2.5. EfficientNet

EfficientNet adalah model *Convolutional Neural Network* (CNN) yang diperkenalkan oleh *Google Research* untuk menyeimbangkan efisiensi komputasi dan akurasi model pada *computer vision*. Berbeda dengan pendekatan konvensional yang meningkatkan kapasitas jaringan secara manual dengan hanya memperdalam lapisan (*depth*), memperlebar kanal (*width*), atau memperbesar resolusi input (*resolution*) secara terpisah, *EfficientNet* menggunakan pendekatan *Neural Architecture Search* (NAS) untuk menemukan arsitektur *baseline* yang optimal. Arsitektur ini kemudian diskalakan menggunakan metode *compound scaling* yang secara sistematis menyeimbangkan ketiga dimensi tersebut agar kinerja model meningkat secara linier tanpa lonjakan biaya komputasi yang sia-sia [18].

2.6. Varian Model EfficientNet

EfficientNet memiliki beberapa varian, yang dibedakan berdasarkan jumlah resolusi input, jumlah

parameter, dan *FLOPs*. Varian *EfficientNet* dapat dilihat pada Tabel 1 berikut.

Tabel 1. Varian Model *EfficientNet* [6]

Varian <i>EfficientNet</i>	Resolusi Input	Parameter	FLOPs
<i>EfficientNet-B0</i>	224x224	5.3	0.39
<i>EfficientNet-B1</i>	240x240	7.8	0.70
<i>EfficientNet-B2</i>	260x260	9.2	1.0
<i>EfficientNet-B3</i>	300x300	12	1.8
<i>EfficientNet-B4</i>	380x380	19	4.2
<i>EfficientNet-B5</i>	456x456	30	9.9
<i>EfficientNet-B6</i>	528x528	43	19
<i>EfficientNet-B7</i>	600x600	66	37


2.7. Transfer Learning

Transfer Learning memungkinkan penggunaan kembali pengetahuan dari model yang sudah ada untuk menyelesaikan tugas baru [19].

Penelitian oleh [20] menyoroti keunggulan teknik ini dalam ranah pengolahan citra, yaitu kemampuannya mengurangi kebutuhan komputasi awal serta meningkatkan akurasi pada kondisi data yang minim. Model *pre-trained* yang telah belajar dari dataset masif dapat disesuaikan kembali (*fine-tuning*) untuk mengenali karakteristik visual yang unik pada dataset lukisan.

3. METODE PENELITIAN

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian. Tahapan metodologi penelitian dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Metodologi Penelitian

3.1. Studi Literatur

Tahapan ini dimulai dengan melakukan pembelajaran literatur berupa jurnal dan buku terkait topik penelitian ini, yaitu penerapan arsitektur *EfficientNet* dalam klasifikasi citra digital, khususnya pada genre seni lukis. Pembelajaran tidak terfokus hanya pada literatur yang membahas klasifikasi genre seni lukis.

3.2. Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan *dataset* berupa citra digital seni-seni lukis. Penelitian ini menggunakan 2 sumber *dataset* dari *Kaggle* dan dapat diakses secara publik yaitu sumber pertama merupakan *dataset* komprehensif yang berisikan tentang sejumlah genre dari seni lukis dengan nama *WikiArt Art Movements/Styles* yang diciptakan oleh

Sivar Azad yang bisa diakses di <https://www.kaggle.com/datasets/sivarazadi/wikiart-art-movementsstyles> [21].

Sumber kedua merupakan gambar seni lukis yang diciptakan oleh pengguna dengan nama Bryanb, *dataset* tersebut bernama *Abstract Art Gallery* yang bisa diakses di <https://www.kaggle.com/datasets/bryanb/abstract-art-gallery> [22].

Tabel 2. *Dataset Abstract Art Gallery*

Judul Genre	Direktori	Jumlah Data
Abstract	1	2.872 Gambar
	2	90 Gambar

Tabel 3. *Dataset WikiArt Art Movements/Styles*

Judul Genre	Jumlah Data
Academic Art	1.305 Gambar
Art Nouveau	3.035 Gambar
Baroque	5.312 Gambar
Expressionism	2.607 Gambar
Japanese Art	2.235 Gambar
Neoclassicism	3.115 Gambar
Primitivism	1.324 Gambar
Realism	5.373 Gambar
Renaissance	6.192 Gambar
Rococo	2.521 Gambar
Romanticism	6.813 Gambar
Symbolism	1.510 Gambar
Western Medieval	1.158 Gambar

Setelah dikumpulkan maka genre yang digunakan akan dibatasi menjadi hanya 7 jenis, seperti yang ada pada Tabel 4 dibawah ini.

Tabel 4. *Dataset yang digunakan*


Judul Genre	Jumlah Data
Abstract	2.962 Gambar
Expressionism	2.607 Gambar
Neoclassicism	3.115 Gambar
Primitivism	1.324 Gambar
Realism	5.373 Gambar
Romanticism	6.813 Gambar
Symbolism	1.510 Gambar
Total	23.704 Gambar

3.3. Perancangan

Pada tahap ini dilakukan perancangan sistem klasifikasi genre lukisan berbasis citra digital menggunakan arsitektur *EfficientNet*. Proses dimulai dengan penyiapan *dataset* yang terdiri dari 7 kategori, kemudian dilakukan pra-pemrosesan untuk menyeragamkan input citra. Pada data latih diterapkan augmentasi *Random Resized Crop* menjadi ukuran 256x256 piksel, sedangkan pada data uji dilakukan *Resize* dan *Center Crop* dengan ukuran yang sama, kemudian seluruh citra dinormalisasi menggunakan nilai rata-rata dan standar deviasi.

Selanjutnya, model dilatih menggunakan varian *EfficientNet* B0 hingga B7 dengan bobot awal dari *ImageNet*, serta dilakukan modifikasi pada bagian *classifier*. Proses pelatihan menggunakan fungsi *Cross*

Entropy Loss selama 20 epoch dengan mekanisme penyimpanan model terbaik berdasarkan akurasi pelatihan tertinggi. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score* yang diperoleh dari *confusion matrix*, serta analisis efisiensi komputasi yang meliputi jumlah parameter, ukuran model, *FLOPs*, dan waktu pelatihan untuk menentukan varian *EfficientNet* yang paling optimal. Skema perancangan penelitian ditunjukkan pada Gambar 3.



Gambar 3. Skema Perancangan *EfficientNet*

3.4. Implementasi

Pada tahapan ini dilakukan implementasi klasifikasi lukisan menggunakan berbagai varian arsitektur *EfficientNet*, meliputi arsitektur *EfficientNet-B0* hingga *EfficientNet-B7*. Implementasi dilakukan dengan library *PyTorch* dan *torchvision* untuk menggunakan varian-varian *EfficientNet*. Model dilatih selama 20 epoch dengan pengaturan *learning rate*, *batch size* yang disesuaikan dengan ukuran model yaitu 16, 8, dan 4, optimasi *AdamW*, serta fungsi *Cross Entropy Loss*. Selain itu, diterapkan mekanisme *learning rate scheduler* (*StepLR*) untuk mengoptimalkan proses pelatihan.

3.5. Pengujian

Pada tahapan ini, sistem yang telah dibuat akan dilakukan uji coba terhadap data uji. Pengujian dilakukan dengan melakukan evaluasi pada tiap varian arsitektur dengan menghitung metrik berupa *accuracy*, *precision*, *recall*, dan *f1-score* dari *confusion matrix*. *Accuracy*, *precision*, *recall*, dan *f1-score* dapat dilihat dalam persamaan berikut.

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \times 100\% \quad (4)$$

Keterangan:

TP: Jumlah data positif yang terklasifikasi dengan benar oleh sistem

TN: Jumlah data negatif yang terklasifikasi dengan benar oleh sistem

FN: Jumlah data negatif yang terklasifikasi dengan salah oleh sistem

FP: Jumlah data positif yang terklasifikasi dengan salah oleh sistem

Selain itu, performa model juga dianalisa berdasarkan metrik efisiensi komputasi, meliputi *FLOPs*, *size model*, jumlah parameter, dan *training time* dibandingkan dengan *ResNet-50*.

4. HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil penelitian yang telah dilakukan melalui proses pelatihan dan pengujian model. Hasil yang diperoleh difokuskan pada tingkat akurasi terbaik serta efisiensi komputasi yang optimal dari penerapan arsitektur *EfficientNet* varian B0 hingga B7.

4.1. Skenario Pengujian

Skenario pengujian pada penelitian ini dilakukan dengan menguji varian model secara terpisah untuk mengetahui performa klasifikasi yang dihasilkan dengan menggunakan metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *f1-score* yang diperoleh dari *confusion matrix*. Selain itu, pengujian juga mencakup analisis efisiensi komputasi yang meliputi jumlah parameter, ukuran model, nilai *FLOPs*, waktu pelatihan, serta *batch size* pada setiap model. Hasil pengujian tersebut kemudian dibandingkan dengan arsitektur *ResNet-50* sebagai model pembanding untuk mengetahui keseimbangan antara akurasi klasifikasi dan biaya komputasi, sehingga dapat ditentukan varian *EfficientNet* yang paling optimal.

4.2. Hasil Pengujian

Hasil pengujian terhadap arsitektur *EfficientNet* varian B0 hingga B7 pada klasifikasi gaya seni lukis dapat dilihat pada Tabel 5 berikut ini.


Tabel 5. Hasil Pengujian Model

Model	Batch Size	Training Time (menit: detik)	Size Model	Accuracy
<i>EfficientNet-B0</i>	8	176:23	18.1	0.7496
	16	165:17		0.8358
	32	164:60		0.8919
<i>EfficientNet-B1</i>	8	183:25	27.8	0.8225
	16	164:00		0.8796
	32	170:53		0.9245
<i>EfficientNet-B2</i>	8	181:4	32.6	0.7612
	16	167:28		0.8587
	32	166:23		0.9045
<i>EfficientNet-B3</i>	8	185:20	44.4	0.7815
	16	171:33		0.8761
	32	158:49		0.9191
<i>EfficientNet-B4</i>	8	195:53	71.2	0.8824
	16	182:16		0.9293
	32	167:11		0.9493
<i>EfficientNet-B5</i>	8	216:53	113.1	0.7768
	16	188:3		0.8546
	32	172:50		0.9102

Model	Batch Size	Training Time (menit: detik)	Size Model	Accuracy
EfficientNet-B6	8	236:56	161.1	0.7689
	16	191:54		0.8638
	32	205:36		0.9301
EfficientNet-B7	8	263:53	250	0.7562
	16	209:16		0.8369
	32	N/A	N/A	N/A

Berdasarkan hasil pengujian pada Tabel 5, variasi *batch size* memberikan pengaruh yang signifikan terhadap kinerja model, baik dari sisi akurasi maupun waktu pelatihan. Secara umum, peningkatan *batch size* dari 8 menjadi 16 dan 32 menunjukkan peningkatan akurasi pada hampir seluruh varian *EfficientNet* karena jumlah data yang lebih banyak dalam setiap pembaruan bobot mampu meningkatkan kestabilan proses pelatihan. Pada *EfficientNet-B0*, akurasi meningkat dari 0,7496 pada *batch size* 8 menjadi 0,8358 pada *batch size* 16 dan mencapai 0,8919 pada *batch size* 32. Pola peningkatan yang sama juga terjadi pada *EfficientNet-B1*, B2, dan B3. Varian *EfficientNet-B4* memperoleh akurasi tertinggi sebesar 0,9493 pada *batch size* 32 pada *epoch* ke-20, yang menunjukkan kemampuan model dalam mengenali karakteristik visual gaya seni lukis.


Pada varian yang lebih besar seperti *EfficientNet-B5* dan B6, peningkatan akurasi diikuti oleh bertambahnya waktu pelatihan akibat meningkatnya jumlah parameter dan kompleksitas perhitungan. *EfficientNet-B7* tidak dapat dijalankan pada *batch size* 32 karena keterbatasan memori perangkat keras sehingga hanya diuji hingga *batch size* 16 dengan akurasi 0,8639. Kondisi ini semakin jelas ketika dibandingkan dengan arsitektur *ResNet-50* yang memiliki sekitar 26 juta parameter dan kebutuhan komputasi mencapai 4,1 miliar *FLOPs* [6], yang menunjukkan beban komputasi yang besar. Sebaliknya, varian *EfficientNet* memiliki jumlah parameter dan kebutuhan *FLOPs* yang lebih rendah sebagaimana ditunjukkan pada Tabel 1 sehingga mampu memberikan kinerja klasifikasi yang tinggi dengan efisiensi komputasi yang lebih baik.



Gambar 4. Confusion Matrix EfficientNet-B0


Untuk melihat performa klasifikasi secara lebih rinci pada setiap kelas gaya seni lukis, dilakukan analisis menggunakan *confusion matrix* pada model dengan akurasi tertinggi pada masing-masing konfigurasi *batch size*.

Gambar 4 menunjukkan *confusion matrix* hasil pengujian model *EfficientNet-B0* dengan *batch size* 32. Pada *confusion matrix*, baris menunjukkan kelas sebenarnya dan kolom menunjukkan kelas prediksi model. Nilai pada diagonal utama menunjukkan prediksi yang benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Hasil pengujian menunjukkan performa yang cukup baik pada kelas *Romanticism* 936 data, *Realism* 562 data, *Abstract* 466 data, dan *Expressionism* 427 data. Namun masih terdapat kesalahan, terutama kelas *Neoclassicism* yang sering diprediksi sebagai *Romanticism* 259 data, *Realism* sebagai *Romanticism* 394 data, serta *Romanticism* sebagai *Realism* 255 data. Selain itu, performa pada kelas *Primitivism* 153 data dan *Symbolism* 156 data relatif lebih rendah, yang menunjukkan bahwa model masih kesulitan membedakan beberapa gaya seni yang memiliki kemiripan karakteristik visual.




Gambar 5. Confusion Matrix EfficientNet-B1

Gambar 5 menampilkan hasil *confusion matrix* model *EfficientNet-B1* dengan *batch size* 32, model menunjukkan performa yang cukup baik dalam mengklasifikasikan gaya seni. Hal ini terlihat dari tingginya prediksi benar pada beberapa kelas utama. Kelas *Romanticism* memiliki jumlah prediksi benar tertinggi, yaitu 956 data, diikuti oleh *Realism* 551 data dan *Abstract* 486 data. Selain itu, kelas *Expressionism* dan *Neoclassicism* juga menunjukkan performa yang cukup stabil. Namun, masih terdapat kesalahan antara kelas *Realism* dan *Romanticism*. Kelas *Neoclassicism* juga cukup sering diklasifikasikan sebagai *Romanticism*. Hal ini mengindikasikan adanya kemiripan karakteristik visual antar kelas tersebut.




Gambar 6. Confusion Matrix EfficientNet-B2

Berdasarkan Gambar 6 hasil pengujian model *EfficientNet-B2* dengan *batch size* 32, dapat diketahui bahwa kelas *Romanticism* memiliki jumlah prediksi benar tertinggi, yaitu sebanyak 1008 data, diikuti oleh *Abstract* dengan 480 data dan *Realism* dengan 512 data. Kelas *Expressionism* dan *Neoclassicism* dengan masing-masing 404 data dan 311 data prediksi benar. Namun, masih terdapat kesalahan klasifikasi, antara kelas *Realism* dan *Romanticism*. Kelas *Realism* diprediksi sebagai *Romanticism* sebanyak 469 data, sedangkan *Romanticism* diklasifikasikan sebagai *Realism* sebanyak 227 data. Selain itu, kelas *Neoclassicism* diklasifikasikan sebagai *Romanticism* dengan 245 data. Kelas *Primitivism* dan *Symbolism* menunjukkan jumlah prediksi benar yang relatif lebih rendah, masing-masing sebesar 151 dan 153 data.



Gambar 7. Confusion Matrix EfficientNet-B3


Gambar 7 menunjukkan hasil *confusion matrix* pengujian model *EfficientNet-B3* dengan *batch size* 32, dapat diketahui bahwa model menunjukkan performa yang cukup baik dalam mengklasifikasikan gaya seni. Kelas *Romanticism*, *Realism*, dan *Abstract* memiliki jumlah prediksi benar tertinggi, masing-masing sebesar 913, 571, dan 474 data. Kelas *Expressionism* dan *Neoclassicism* juga menunjukkan hasil yang relatif stabil. Kelas *Primitivism* dan *Symbolism* menunjukkan performa yang relatif lebih rendah dibandingkan kelas lainnya.



Gambar 8. Confusion Matrix EfficientNet-B4

Gambar 8 menunjukkan *confusion matrix* hasil pengujian model *EfficientNet-B4* dengan *batch size* 32. Model ini menunjukkan performa klasifikasi yang sangat baik pada hampir seluruh kelas gaya seni. Kelas *Romanticism*, *Realism*, dan *Abstract* memiliki jumlah prediksi benar tertinggi yaitu 980, 645, dan 494 data, sedangkan kelas *Expressionism* 429 data dan *Neoclassicism* 308 data yang diprediksi benar. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual setiap kelas dengan lebih akurat dibandingkan model lainnya.


Secara keseluruhan, *EfficientNet-B4* memiliki distribusi nilai diagonal yang paling tinggi dan konsisten dibandingkan varian *EfficientNet* lainnya. Oleh karena itu, *EfficientNet-B4* dapat disimpulkan sebagai model terbaik dalam penelitian ini karena memberikan performa klasifikasi paling optimal serta memiliki kemampuan generalisasi yang lebih baik dalam membedakan gaya seni yang memiliki kemiripan visual.



Gambar 9. Confusion Matrix EfficientNet-B5


Gambar 9 menunjukkan *confusion matrix* *EfficientNet-B5* dengan *batch size* 32, model menunjukkan performa klasifikasi yang cukup baik, terlihat dari tingginya nilai prediksi benar pada diagonal utama, khususnya pada kelas *Romanticism*, *Realism*, *Abstract*, dan *Expressionism*. Namun, masih terdapat misklasifikasi yang signifikan, terutama

antara *Realism* dan *Romanticism* serta *Neoclassicism* dan *Romanticism*, yang mengindikasikan adanya kemiripan karakteristik visual antar gaya tersebut sehingga model kesulitan membedakan fitur yang lebih spesifik. Secara umum, model telah bekerja dengan baik, tetapi masih memerlukan optimalisasi untuk meningkatkan pemisahan antar kelas yang memiliki kemiripan visual tinggi.



Gambar 10. Confusion Matrix EfficientNet-B6

Gambar 10 menunjukkan hasil *confusion matrix* *EfficientNet-B6* batch size 32, model menunjukkan kinerja yang baik dengan jumlah prediksi benar yang tinggi pada kelas *Romanticism* 994 data, *Realism* 561 data, *Abstract* 467 data, *Expressionism* 428, *Neoclassicism* 308, *Primitivism* 157 data, dan *Symbolism* 173 data. Namun, masih terdapat misklasifikasi yang cukup signifikan, terutama antara *Realism* yang diprediksi sebagai *Romanticism* 404 data dan *Romanticism* yang diprediksi sebagai *Realism* 239 data, serta *Neoclassicism* yang diprediksi sebagai *Romanticism* 228 data.



Gambar 11. Confusion Matrix EfficientNet-B7

Gambar 11 menunjukkan hasil *confusion matrix* *EfficientNet-B7* dengan batch size 16 model menunjukkan performa yang baik dengan jumlah prediksi benar yang tinggi pada kelas *Romanticism* 907 data, *Realism* 537 data, *Abstract* 469 data, *Expressionism* 427 data, *Neoclassicism* 285 data,

Primitivism 164 data, dan *Symbolism* 151 data. Namun, misklasifikasi masih cukup dominan antara *Realism* yang diprediksi sebagai *Romanticism* sebanyak 411 data dan *Romanticism* yang diprediksi sebagai *Realism* 290 data, serta *Neoclassicism* yang diprediksi sebagai *Romanticism* sebanyak 237 data.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian terhadap 23.704 citra dari tujuh gaya seni lukis dengan delapan varian *EfficientNet* (B0–B7), dapat disimpulkan bahwa arsitektur *EfficientNet* mampu memberikan kinerja klasifikasi yang tinggi dengan efisiensi komputasi yang baik. Peningkatan *batch size* terbukti berkontribusi terhadap peningkatan performa pada hampir seluruh varian model. Dari seluruh arsitektur yang diuji, *EfficientNet-B4* dengan *batch size* 32 menunjukkan performa terbaik dengan akurasi tertinggi sebesar 94,93% (0,9493) pada *epoch* ke-20. Hasil *confusion matrix* memperlihatkan bahwa model ini memiliki distribusi prediksi benar yang paling konsisten serta tingkat kesalahan klasifikasi yang relatif lebih rendah dibandingkan varian lainnya. Selain unggul dalam akurasi, *EfficientNet-B4* juga menunjukkan keseimbangan yang optimal antara performa dan kebutuhan komputasi dibandingkan varian yang lebih besar seperti B5, B6, dan B7 yang memerlukan waktu pelatihan dan sumber daya lebih tinggi. Berdasarkan penelitian ini untuk penelitian selanjutnya disarankan melakukan optimalisasi *fine-tuning* secara lebih mendalam, menerapkan teknik augmentasi data yang lebih beragam, serta melakukan pengujian pada *dataset* yang lebih luas dan bervariasi guna meningkatkan kemampuan generalisasi model dan meminimalkan kesalahan klasifikasi pada gaya seni yang memiliki kemiripan visual tinggi.

DAFTAR PUSTAKA

- [1] M. W. K. Al-Bahrani, I. Ratnawati, and A. R. Prasetyo, "Nilai Pendidikan Kesenian Wayang Beber Pacitan sebagai Ide Penciptaan Ilustrasi Dekoratif Digital," *JoLLA J. Lang. Lit. Arts*, vol. 2, no. 11, pp. 1505–1524, 2022, doi: 10.17977/um064v2i112022p1505-1524.
- [2] Q. Li, Y. Li, and F. Qiu, "Research on automatic classification method of artistic styles based on attention mechanism convolutional neural network," *Int. J. Low-Carbon Technol.*, vol. 19, no. May, pp. 2018–2023, 2024, doi: 10.1093/ijlct/ctae114.
- [3] X. Zhang and T. Ding, "Style classification of media painting images by integrating ResNet and attention mechanism," *Heliyon*, vol. 10, no. 6, p. e27178, 2024, doi: 10.1016/j.heliyon.2024.e27178.
- [4] W. Li, "Enhanced automated art curation using supervised modified CNN for art style classification," *Sci. Rep.*, vol. 15, no. 1, pp. 1–18, 2025, doi: 10.1038/s41598-025-91671-z.
- [5] Q. Dong, "The Classification of Painting Art

- Styles in Art Teaching Based on Machine Learning from the Perspective of Affective Semantic Analysis,” *Arch. des Sci.*, vol. 74, no. s1, pp. 103–108, 2024, doi: 10.62227/as/74s115.
- [6] R. Nurmalika, M. Makmun, B. Yulianto, I. Mursidah, D. Sweetania, and P. Sularsih, “Paradigma Klasifikasi Ragam Seni Lukis Berbasis Convolutional Neural Network (CNN) Dengan MobileNetV2 Dan Implementasi Pada Postman Melalui Flask Api,” *J. Minfo Polgan*, vol. 13, no. 2, pp. 2351–2363, 2025, doi: 10.33395/jmp.v13i2.14457.
- [7] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *36th Int. Conf. Mach. Learn. ICML 2019*, pp. 10691–10700, 2020.
- [8] M. Alruwaili and M. Mohamed, “An Integrated Deep Learning Model with EfficientNet and ResNet for Accurate Multi-Class Skin Disease Classification,” *Diagnostics*, vol. 15, no. 5, pp. 1–18, 2025, doi: 10.3390/diagnostics15050551.
- [9] A. Ishaq, F. U. M. Ullah, P. Hamandawana, D. J. Cho, and T. S. Chung, “Improved EfficientNet Architecture for Multi-Grade Brain Tumor Detection,” *Electron.*, vol. 14, no. 4, pp. 1–20, 2025, doi: 10.3390/electronics14040710.
- [10] J. M. Fortuna-Cervantes, C. Soubervielle-Montalvo, C. A. Puente-Montejano, O. E. Pérez-Cham, and R. Peña-Gallardo, “Evaluation of CNN Models with Transfer Learning in Art Media Classification in Terms of Accuracy and Class Relationship,” *Comput. y Sist.*, vol. 28, no. 1, pp. 233–244, 2024, doi: 10.13053/CyS-28-1-4895.
- [11] T. Dhoom and T. Sayeed, “Artwork classification and recognition system based on Convolutional Neural Network,” vol. 5, no. May, 2022.
- [12] R. S. S. Anwar, “Multidisciplinary Science Studi Seni Lukis Realisme Karya Robi Fathoni,” *J. Ilm. Teknol. Inf. Asia*, vol. 15, no. 1, pp. 1–19, 2024, doi: 10.1186/s12864-019-6413-7.
- [13] B. Habriantono, R. Masnilah, and F. K. Alfariy, “Pengelolaan Serangan Kutu Kebul (Bemisi tabaci Genn.) pada Tanaman Cabai (*Capsicum annum* L.) di Rumah Kaca,” *J. Ilm. Inov.*, vol. 24, no. 2, pp. 131–139, 2024, [Online]. Available: <https://publikasi.polije.ac.id/jii/article/view/4650>
- [14] P. A. Nugroho, I. Fenriana, and R. Arijanto, “Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia,” *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [15] M. Tamba, “Analisis dan implementasi teknologi deep learning dalam pengolahan citra digital,” *Circ. Arch.*, vol. 1, no. 6, pp. 1–7, 2024.
- [16] I. Nihayatul Husna, M. Ulum, A. Kurniawan Saputro, D. Tri Laksono, and D. Neipa Purnamasari, “Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN),” *Semin. Nas. Fortei Reg.*, vol. 7, no. 5, pp. 1–6, 2022.
- [17] S. Yuliany, Aradea, and Andi Nur Rachman, “Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN),” *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [18] A. Abdelrahman and S. Viriri, “EfficientNet family U-Net models for deep learning semantic segmentation of kidney tumors on CT images,” *Front. Comput. Sci.*, vol. 5, 2023, doi: 10.3389/fcomp.2023.1235622.
- [19] J. Plested, M. Phiri, and T. Gedeon, “Deep transfer learning for image classification: a survey,” 2025, doi: 10.1007/s10462-026-11491-z.
- [20] A. W. Salehi, S. Khan, G. Gupta, B. I. Alabduallah, A. Almjally, H. Alsolai, T. Siddiqui, A. Mellit, “A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope,” *Sustain.*, vol. 15, no. 7, 2023, doi: 10.3390/su15075930.
- [21] S. Azad, “WikiArt Art Movements/Styles,” *Kaggle Dataset*, 2023. [Online]. Available: <https://www.kaggle.com/datasets/sivarazadi/wikiart-art-movementsstyles>
- [22] Bryanb, “Abstract Art Gallery,” *Kaggle Dataset*, 2020. [Online]. Available: <https://www.kaggle.com/datasets/bryanb/abstract-art-gallery>