

Perbandingan Efficientnet, Visual Geometry Group 16, dan Residual Network 50 Untuk Klasifikasi Kendaraan Bermotor

Andrianto*, Imam Tahyudin, Giat Karyono

Fakultas Ilmu Komputer, Magister Komputer, Universitas Amikom Purwokerto, Indonesia

Email: ¹23MA41D024@students.amikompurwokerto.ac.id ²imam.tahyudin@amikompurwokerto.ac.id

³giatkaryono@amikompurwokerto.ac.id Email Penulis Korespondensi: 23MA41D024@students.amikompurwokerto.ac.id

Submitted: 14/12/2024; Accepted: 29/12/2024; Published: 30/12/2024

Abstrak—Penelitian ini membandingkan kinerja tiga model Convolutional Neural Network (CNN), yaitu EfficientNet, VGG16, dan ResNet50, dalam tugas klasifikasi kendaraan bermotor menggunakan dataset "Car vs Bike." Pendekatan transfer learning diterapkan dengan bobot pretrained dari ImageNet. Hasil penelitian menunjukkan bahwa VGG16 memiliki kinerja terbaik dengan akurasi 95%, precision 0,95, recall 0,96, dan F1-score 0,95, serta keseimbangan tinggi dalam mengenali kedua kelas. ResNet50 mencapai akurasi 87% pada dataset pengujian dengan precision 0,89, recall 0,84, dan F1-score 0,87, menawarkan kompromi antara akurasi dan efisiensi komputasi. Sebaliknya, EfficientNet menunjukkan performa terendah dengan akurasi 50% dan gagal mengenali kelas "Car," ditunjukkan dengan precision dan recall sebesar 0,00. Faktor-faktor seperti kompleksitas arsitektur, bias dataset, dan efisiensi komputasi memengaruhi hasil ini. Studi ini memperkuat temuan sebelumnya tentang kekuatan dan kelemahan model CNN dalam aplikasi klasifikasi kendaraan bermotor. Selain itu, penelitian ini menyoroti pentingnya pengelolaan data yang seimbang dan pemilihan model berdasarkan kebutuhan spesifik aplikasi. Namun, keterbatasan dataset dengan hanya dua kelas dan ketergantungan pada transfer learning menjadi area untuk pengembangan di masa depan. Hasil ini memberikan wawasan bagi pengembangan sistem transportasi cerdas yang membutuhkan akurasi tinggi dan efisiensi.

Kata Kunci: Klasifikasi Kendaraan; Convolutional Neural Network (CNN); EfficientNet; VGG16; ResNet50; Transfer Learning

Abstract—This study compares the performance of three Convolutional Neural Network (CNN) models—EfficientNet, VGG16, and ResNet50—in motor vehicle classification tasks using the "Car vs Bike" dataset. Transfer learning was applied using pretrained weights from ImageNet. The results indicate that VGG16 achieved the best performance with 95% accuracy, precision of 0.95, recall of 0.96, and an F1-score of 0.95, demonstrating high balance in recognizing both classes. ResNet50 attained 87% accuracy on the test dataset with a precision of 0.89, recall of 0.84, and an F1-score of 0.87, offering a trade-off between accuracy and computational efficiency. Conversely, EfficientNet exhibited the lowest performance with 50% accuracy, failing to recognize the "Car" class effectively, as evidenced by precision and recall values of 0.00. Factors such as architectural complexity, dataset bias, and computational efficiency influenced these outcomes. This study reinforces previous findings on the strengths and weaknesses of CNN models in motor vehicle classification applications. Furthermore, it highlights the importance of balanced data management and model selection tailored to specific application requirements. However, the dataset's limitation of only two classes and reliance on transfer learning remain areas for future improvement. These findings provide valuable insights for developing intelligent transportation systems requiring high accuracy and efficiency.

Keywords: Vehicle Classification; Convolutional Neural Network (CNN); EfficientNet; VGG16; ResNet50; Transfer Learning

1. PENDAHULUAN

Klasifikasi citra, khususnya dalam konteks identifikasi kendaraan, menghadirkan tantangan signifikan akibat berbagai faktor seperti kondisi pencahayaan, sudut pandang, latar belakang, dan kualitas gambar. Tantangan ini sangat krusial dalam aplikasi seperti sistem transportasi cerdas, di mana akurasi pengenalan kendaraan sangat penting untuk manajemen lalu lintas dan keselamatan. Variabilitas yang ada dalam gambar menjadi salah satu kesulitan utama dalam klasifikasi citra. Bi et al. menyoroti bahwa meskipun ada kemajuan dalam teknik klasifikasi citra, tugas ini tetap menantang karena variasi dalam pencahayaan, latar belakang, rotasi, dan obstruksi [1]. Selain faktor lingkungan, aspek teknologi dalam sistem identifikasi kendaraan juga memainkan peran penting. Moon dan Park menekankan pentingnya sensor penglihatan canggih dan metode cerdas dalam mendeteksi serta membedakan objek, yang sangat diperlukan untuk tugas seperti pencegahan tabrakan belakang [2]. Terakhir, pentingnya pemrosesan waktu nyata dalam identifikasi kendaraan tidak bisa dipandang sebelah mata. Shekhar dan Saha menegaskan bahwa identifikasi waktu nyata merupakan komponen krusial dalam sistem transportasi cerdas, di mana pengenalan kendaraan yang cepat dan akurat sangat diperlukan untuk manajemen lalu lintas yang efektif [3].

Dalam menghadapi tantangan tersebut, berbagai model Convolutional Neural Network (CNN) telah diusulkan, termasuk Visual Geometry Group 16 (VGG16), Residual Network 50 (ResNet50), dan EfficientNet, yang masing-masing memiliki kelebihan dan kekurangan yang relevan dengan tugas klasifikasi kendaraan. VGG16, yang dikembangkan oleh Visual Geometry Group di Oxford, dikenal karena kesederhanaan dan kedalamannya. Arsitekturnya yang terdiri dari 16 lapisan telah terbukti efektif dalam berbagai tugas klasifikasi citra. VGG16 berhasil mencapai kesuksesan signifikan dalam ILSVRC 2014 (ImageNet Large Scale Visual Recognition Challenge), yang menjadikannya acuan bagi model-model berikutnya [4]. Kemampuannya dalam mengekstraksi fitur hierarkis dari gambar membuatnya menjadi kandidat yang kuat untuk identifikasi kendaraan, di mana membedakan antara berbagai jenis dan model kendaraan sangat penting. Di sisi lain, ResNet50 memperkenalkan konsep residual learning, yang memungkinkan pelatihan jaringan yang jauh lebih dalam tanpa masalah hilangnya gradien. Dengan 50 lapisan,

arsitektur ini telah terbukti mengungguli banyak model lain dalam berbagai tugas klasifikasi. Mirzazadeh et al. mencatat bahwa ResNet50 menunjukkan kinerja yang lebih baik dalam hal akurasi dibandingkan VGG16 dalam studi mereka mengenai klasifikasi citra [5]. Karakteristik ini menjadikan ResNet50 sangat menarik untuk aplikasi yang membutuhkan presisi tinggi, seperti identifikasi kendaraan dalam kondisi yang beragam. Terakhir, EfficientNet, sebagai kemajuan terbaru dalam arsitektur CNN, dirancang untuk mengoptimalkan akurasi dan efisiensi secara bersamaan. Keluarga model ini menskalakan kedalaman, lebar, dan resolusi jaringan secara seimbang, yang menghasilkan peningkatan kinerja yang signifikan sambil meminimalkan biaya komputasi [6]. Wongpanich et al. menyoroti bahwa EfficientNet mampu mencapai akurasi terbaik pada benchmark seperti ImageNet, dengan memerlukan lebih sedikit parameter dan daya komputasi dibandingkan dengan pendahulunya [6].

Penelitian Hafeez et al. mengkaji performa CNN dalam klasifikasi gambar biner menggunakan dataset Car vs. Bike. Dataset ini terdiri dari gambar kendaraan bermotor dengan 2000 gambar untuk setiap kelas (mobil dan sepeda motor) [7]. CNN digunakan sebagai baseline untuk membandingkan performa dengan model H-QNN yang mereka usulkan. Arsitektur CNN terdiri dari enam lapisan konvolusional, diikuti oleh tiga lapisan fully connected. Setiap lapisan konvolusional dilengkapi dengan fungsi aktivasi ReLU dan pooling untuk ekstraksi fitur spasial. Pada pengujian, CNN menunjukkan akurasi 88,2%, menjadikan penelitian ini relevan dalam mengevaluasi performa model CNN modern. Penelitian ini berbeda karena membandingkan tiga model berbeda (VGG16, ResNet50, dan EfficientNet) untuk klasifikasi citra kendaraan (mobil dan sepeda motor), yang belum banyak dilakukan secara langsung dalam literatur yang ada. Hal ini memberikan kontribusi baru dalam memahami kekuatan dan kelemahan setiap model dalam tugas klasifikasi kendaraan bermotor pada dataset yang sama.

Beberapa penelitian sebelumnya telah mengeksplorasi penggunaan model CNN untuk klasifikasi kendaraan, baik dalam konteks klasifikasi dua kelas (kendaraan vs non-kendaraan) maupun aplikasi pengenalan objek secara lebih luas. [8] dalam studi mereka berjudul "Deep Learning-Based Vehicle Classification for Low Quality Images" menyoroti tantangan klasifikasi kendaraan menggunakan citra berkualitas rendah. Penelitian ini menguji berbagai arsitektur CNN untuk membedakan kendaraan dari non-kendaraan, yang relevan untuk memahami performa model pada tugas klasifikasi dua kelas dalam kondisi citra yang kurang ideal [8].

Pada sisi lain, [9] melakukan perbandingan kuantitatif dan kualitatif terhadap 18 model CNN, termasuk VGG16 dan ResNet50, untuk klasifikasi citra medis, khususnya diagnosis COVID-19 menggunakan gambar Rontgen dada (CXR). Hasil penelitian ini memberikan wawasan mengenai kelebihan dan kekurangan masing-masing model, dan relevansi temuan ini untuk aplikasi klasifikasi citra kendaraan, karena baik VGG16 maupun ResNet50 juga sering diterapkan pada berbagai jenis klasifikasi citra [9].

Selain itu, penelitian oleh [10] berjudul "An Improved Convolutional Neural Network Algorithm and Its Application in Multilabel Image Labeling" membahas penggunaan EfficientNet untuk tugas klasifikasi multilabel, termasuk pengenalan kendaraan. Efisiensi dan akurasi arsitektur EfficientNet yang mereka temukan menunjukkan potensinya dalam pengenalan objek, yang sangat relevan untuk penelitian ini dalam menguji model tersebut untuk klasifikasi kendaraan [10].

Dalam penelitian berjudul "Data Complexity Based Evaluation of the Model Dependence of Brain MRI Images for Classification of Brain Tumor and Alzheimer's Disease" melakukan evaluasi berbagai model CNN pada dataset kompleks gambar MRI otak. Penelitian ini membahas bagaimana kompleksitas data mempengaruhi kinerja model CNN, yang dapat memberikan perspektif penting untuk membandingkan performa model-model CNN pada dataset citra yang lebih kompleks, seperti dataset kendaraan [11].

Meskipun telah banyak penelitian yang membandingkan performa berbagai model CNN dalam tugas klasifikasi citra, terutama dalam konteks pengenalan objek, perbandingan langsung antara VGG16, ResNet50, dan EfficientNet untuk klasifikasi kendaraan bermotor, terutama pada dua kelas (mobil vs sepeda motor), masih terbatas. Sebagian besar studi sebelumnya lebih fokus pada klasifikasi citra secara umum atau pada aplikasi pengenalan objek dalam domain yang berbeda, seperti citra medis [9]. Oleh karena itu, terdapat kekosongan literatur yang perlu diisi dalam hal perbandingan performa tiga model CNN utama ini dalam aplikasi klasifikasi kendaraan bermotor, khususnya dalam kondisi dataset yang mengandung berbagai variasi kendaraan dan lingkungan.

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja VGG16, ResNet50, dan EfficientNet dalam tugas klasifikasi kendaraan bermotor menggunakan dataset "Car vs Bike". Fokus utama penelitian ini adalah untuk mengidentifikasi model yang paling efektif dan efisien dalam mengklasifikasikan dua jenis kendaraan (mobil dan sepeda motor) pada dataset yang bervariasi. Selain itu, penelitian ini bertujuan untuk memberikan wawasan tentang kekuatan dan kelemahan masing-masing model dalam menghadapi tantangan klasifikasi citra kendaraan, serta memberikan kontribusi terhadap pengembangan sistem identifikasi kendaraan yang lebih baik dalam aplikasi dunia nyata.

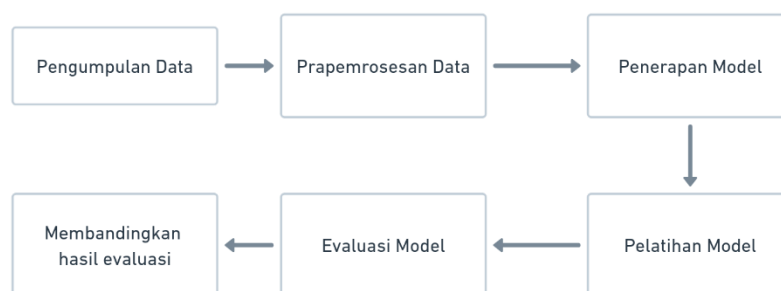
2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini mengikuti tahapan yang terstruktur untuk membangun dan mengevaluasi model deep learning dalam klasifikasi citra kendaraan, yang terdiri dari pengumpulan data, prapemrosesan data, pembangunan model, pelatihan model, evaluasi kinerja, dan analisis hasil. Tahap pertama melibatkan pengumpulan dataset citra kendaraan yang

dibagi menjadi data pelatihan dan data validasi. Data yang dikumpulkan kemudian diproses melalui prapemrosesan, termasuk augmentasi dan normalisasi, untuk memastikan kualitas data yang optimal dalam melatih model. Model yang digunakan adalah ResNet50 dengan teknik transfer learning, diikuti oleh pelatihan model menggunakan data pelatihan yang telah diproses.

Setelah pelatihan, model dievaluasi menggunakan dataset validasi dengan mengukur akurasi dan menganalisis hasil melalui confusion matrix serta classification report. Hasil evaluasi ini memberikan gambaran mengenai kinerja model dalam klasifikasi citra kendaraan dan memberikan dasar untuk analisis lebih lanjut. Berdasarkan hasil tersebut, dilakukan kesimpulan dan saran untuk penelitian selanjutnya, guna meningkatkan akurasi model dan memperluas aplikasinya. Dengan mengikuti tahapan-tahapan ini, penelitian bertujuan menghasilkan model yang efektif dalam mengklasifikasikan kendaraan secara otomatis menggunakan teknologi deep learning. Tahapan penelitian dirancang secara sistematis, mulai dari pengumpulan data, prapemrosesan, hingga evaluasi kinerja model menggunakan berbagai metrik. Flowchart pada Gambar 1 di bawah ini memberikan gambaran menyeluruh tentang alur proses penelitian yang dilakukan.



Gambar 1. Flowchart Penelitian

2.2 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari dua bagian utama, yaitu dataset pelatihan dan dataset pengujian. Dataset pelatihan dan validasi diambil dari sumber Kaggle yang dikelola oleh Utkarsh Saxena [12]. Dataset ini terdiri dari citra kendaraan yang dikelompokkan dalam dua kategori utama, yaitu sepeda motor dan mobil. Dataset ini telah tersedia dalam format yang sesuai untuk pelatihan model klasifikasi citra, dengan struktur folder yang memisahkan gambar berdasarkan label kelas.

Sementara itu, untuk dataset pengujian, gambar-gambar dikumpulkan secara otomatis melalui proses web scraping menggunakan library Bing Image Downloader. Skrip yang digunakan untuk pengunduhan gambar ini melakukan pencarian gambar dengan kata kunci 'Motorcycle' dan 'Car,' menghasilkan total 224 gambar untuk kelas 'Bike' dan 211 gambar untuk kelas 'Car.' Setelah proses pengunduhan, hanya gambar-gambar dengan format file .jpg yang dipertahankan dan dipindahkan ke dalam folder yang telah ditentukan. Dataset ini bertujuan untuk memberikan data baru yang tidak terlihat oleh model selama pelatihan, sehingga dapat digunakan untuk menguji generalisasi model pada gambar yang lebih beragam.

2.3 Prapemrosesan Data

Pada tahap prapemrosesan data, langkah pertama yang dilakukan adalah mengonversi gambar dengan format warna tertentu, yaitu RGBA, ke format RGB jika diperlukan. Proses ini penting karena gambar dengan saluran warna tambahan seperti Alpha (A) yang digunakan untuk transparansi, tidak diperlukan dalam analisis citra yang difokuskan pada klasifikasi objek seperti kendaraan. Mengonversi gambar ke format RGB memastikan konsistensi dan kompatibilitas dengan model pembelajaran mesin yang diimplementasikan, khususnya dengan model pre-trained seperti ResNet50 yang memerlukan input gambar berformat RGB. Untuk itu, digunakan modul Python PIL (Python Imaging Library) yang memungkinkan pemrosesan gambar, termasuk konversi format dan ukuran.

Selanjutnya, untuk meningkatkan variasi dan kualitas data pelatihan, dilakukan teknik augmentasi data menggunakan ImageDataGenerator dari Keras. Augmentasi data merupakan langkah yang penting dalam machine learning untuk meningkatkan performa model dengan cara memperkenalkan variasi citra yang dapat membantu model belajar lebih baik. Dalam penelitian ini, augmentasi yang diterapkan mencakup rotasi gambar dalam rentang 30 derajat, pergeseran gambar secara horizontal dan vertikal hingga 10%, serta pembalikan gambar secara horizontal. Semua augmentasi ini dilakukan untuk mensimulasikan variasi yang mungkin ditemukan pada citra kendaraan dalam kehidupan nyata, seperti perubahan sudut pandang, kondisi pencahayaan, atau orientasi objek. Teknik augmentasi ini tidak hanya memperbanyak jumlah data pelatihan tetapi juga membantu model untuk tidak overfit terhadap data latih yang terbatas.

Selain augmentasi, langkah lain yang dilakukan adalah normalisasi gambar dengan melakukan penskalaan piksel citra menggunakan parameter $\text{rescale}=1/255$. Hal ini dilakukan untuk mengubah rentang nilai piksel gambar dari $[0, 255]$ menjadi $[0, 1]$, sehingga membantu mempercepat konvergensi selama pelatihan dan membuat pelatihan

model lebih stabil. Normalisasi ini penting karena banyak algoritma optimasi, termasuk Adam optimizer yang digunakan dalam penelitian ini, lebih efisien ketika input data berada dalam rentang nilai yang lebih kecil.

Dataset dibagi menjadi dua bagian utama, yaitu data latih dan data validasi. Pembagian ini dilakukan dengan proporsi 80% untuk pelatihan dan 20% untuk validasi, yang dilakukan secara otomatis oleh ImageDataGenerator dengan parameter `validation_split=0.2`. Pembagian data ini penting untuk memastikan bahwa model dapat dievaluasi pada data yang tidak terlihat selama pelatihan, sehingga memberikan gambaran yang lebih baik mengenai kemampuan model dalam menggeneralisasi ke data yang baru.

Distribusi kelas dalam dataset juga dievaluasi pada tahap ini. Visualisasi distribusi kelas digunakan untuk memastikan bahwa tidak ada ketidakseimbangan kelas yang signifikan antara kelas "Bike" dan "Car", yang dapat mempengaruhi kinerja model. Jika ditemukan ketidakseimbangan, langkah-langkah tambahan seperti oversampling atau penyesuaian bobot kelas dapat diterapkan untuk mengatasi masalah tersebut. Namun, dalam penelitian ini, distribusi kelas tampak cukup seimbang antara kedua kategori, sehingga tidak diperlukan penyesuaian lebih lanjut.

Secara keseluruhan, tahap prapemrosesan data ini dirancang untuk memastikan kualitas dan keberagaman data yang digunakan dalam pelatihan, sehingga model dapat belajar dari representasi yang lebih luas dan mampu mengklasifikasikan kendaraan bermotor (mobil dan sepeda motor) dengan akurasi yang tinggi.

2.4 Penerapan Model

Pada penelitian ini, tiga model konvolusional yang telah terbukti efektif untuk berbagai tugas klasifikasi citra diterapkan dan dibandingkan, yaitu VGG16, ResNet50, dan EfficientNet. Ketiga model ini diterapkan menggunakan pendekatan transfer learning, di mana bobot pre-trained dari ImageNet digunakan untuk mempercepat proses pelatihan dan meningkatkan performa model pada dataset yang lebih kecil dan spesifik. Pendekatan transfer learning memungkinkan model untuk memanfaatkan pengetahuan yang sudah dipelajari dari dataset besar, seperti ImageNet, yang berisi jutaan gambar dari berbagai kategori. Hal ini mengurangi kebutuhan akan data pelatihan yang sangat besar, serta mempercepat konvergensi model dalam mempelajari fitur dari dataset yang lebih terbatas. Dalam konteks penelitian ini, model-model tersebut diterapkan untuk klasifikasi citra sepeda motor dan mobil, yang merupakan dua kelas objek yang berbeda.

VGG16 dipilih karena kesederhanaan arsitekturnya yang terdiri dari serangkaian lapisan konvolusi dan pooling. Meskipun arsitektur VGG16 terbilang sederhana, model ini telah terbukti efektif dalam banyak studi klasifikasi citra. VGG16 menggunakan ukuran kernel konvolusi yang kecil (3x3) dan menerapkan banyak lapisan konvolusi untuk mengekstraksi fitur yang lebih mendalam, yang membuatnya tetap kompetitif dalam berbagai aplikasi klasifikasi citra meskipun telah ada model-model yang lebih kompleks [4][13]. Model ini umumnya digunakan sebagai baseline dalam penelitian citra dan sering kali memberikan hasil yang baik pada tugas klasifikasi sederhana hingga menengah. Di sisi lain, ResNet50 dipilih karena menggunakan arsitektur residual learning, yang memungkinkan model untuk memiliki kedalaman lebih banyak tanpa mengalami masalah vanishing gradient. Dengan adanya shortcut connections, informasi yang hilang pada lapisan-lapisan terdalam dapat dilewatkan ke lapisan-lapisan yang lebih awal, memungkinkan pelatihan model yang lebih dalam tanpa penurunan performa. Hal ini menjadikan ResNet50 sebagai pilihan yang sangat efektif untuk tugas klasifikasi citra yang lebih kompleks, seperti pada dataset yang memiliki banyak variasi dalam objek [14][15]. Terakhir, EfficientNet dipilih berkat teknik compound scaling, yang secara bersamaan menyesuaikan kedalaman, resolusi, dan jumlah filter pada jaringan untuk mencapai keseimbangan yang optimal antara akurasi dan efisiensi komputasi. EfficientNet memberikan keuntungan dalam hal parameter yang lebih sedikit dan komputasi yang lebih efisien dibandingkan dengan model-model lain yang sebanding, sambil tetap memberikan akurasi yang sangat baik. Arsitektur ini dirancang dengan pendekatan yang lebih cermat dalam mengoptimalkan sumber daya komputasi, yang memungkinkan model untuk memberikan hasil yang baik dengan jumlah parameter yang lebih sedikit dan kebutuhan komputasi yang lebih rendah [16][17]. Dengan membandingkan ketiga model ini, penelitian ini bertujuan untuk mengevaluasi kinerja masing-masing dalam konteks klasifikasi citra sepeda motor dan mobil, serta memberikan wawasan tentang trade-off antara akurasi dan efisiensi komputasi pada penerapan model deep learning untuk tugas klasifikasi citra.

2.5 Pelatihan Model

Pada penelitian ini, seluruh model (VGG16, ResNet50, dan EfficientNet) dilatih menggunakan Adam optimizer dengan learning rate yang disesuaikan. Penggunaan optimizer Adam ini bertujuan untuk memastikan konvergensi yang cepat dan stabil, karena Adam menggabungkan kelebihan dari momentum dan adaptasi learning rate [18][19]. Di tahap awal pelatihan, lapisan-lapisan dasar pada model-model tersebut dibekukan agar bobot-bobot yang telah dilatih pada dataset ImageNet tetap dipertahankan. Langkah ini mengurangi waktu pelatihan dan mencegah model untuk melupakan fitur-fitur penting yang telah dipelajari sebelumnya [20]. Fungsi loss yang digunakan adalah binary cross-entropy, karena tugas klasifikasi ini hanya melibatkan dua kelas, yaitu sepeda motor dan mobil [21]. Selama pelatihan awal, hanya lapisan-lapisan tambahan yang ditambahkan di atas model dasar yang dilatih, sementara lapisan dasar tetap tidak berubah.

Setelah beberapa epoch pelatihan, dilakukan fine-tuning dengan membuka beberapa lapisan pada model dasar. Tujuannya adalah untuk memungkinkan model menyesuaikan bobot-bobotnya lebih lanjut sesuai dengan karakteristik dan kompleksitas dataset spesifik ini, sehingga dapat meningkatkan performa model dalam klasifikasi dua kelas tersebut [20]). Selain itu, untuk mencegah overfitting, teknik dropout diterapkan dengan nilai dropout sebesar 0,5,

yang membantu mengurangi ketergantungan pada unit-unit tertentu dalam jaringan, sehingga meningkatkan generalisasi model terhadap data yang belum terlihat [22]. GlobalAveragePooling2D juga digunakan setelah lapisan konvolusional terakhir untuk mengurangi dimensi keluaran dan jumlah parameter model, yang pada gilirannya meningkatkan efisiensi model. Teknik ini berfungsi untuk merangkum informasi spasial dari fitur-fitur yang diekstraksi oleh model dasar dan mengurangi risiko overfitting, sekaligus mempercepat proses pelatihan [23][24]. Pelatihan dilakukan dalam dua tahap: pertama, pelatihan dilakukan hanya pada lapisan tambahan, dan kedua, fine-tuning dilakukan dengan membuka sebagian lapisan model dasar untuk meningkatkan akurasi dan kinerja keseluruhan model. Dengan pendekatan ini, diharapkan model dapat memanfaatkan transfer learning secara optimal, sambil terus menyesuaikan dengan data yang lebih spesifik.

2.6 Evaluasi Model

Evaluasi model adalah tahap krusial dalam pengukuran kinerja model deep learning setelah proses pelatihan selesai. Pada penelitian ini, evaluasi dilakukan menggunakan beberapa metrik utama yang umum diterapkan dalam masalah klasifikasi biner, yaitu akurasi, precision, recall, F1-score, dan confusion matrix. Metrik-metrik ini dipilih untuk memberikan gambaran yang komprehensif tentang kemampuan model dalam mengklasifikasikan data ke dalam dua kelas, yaitu mobil dan sepeda motor.

Akurasi adalah metrik yang paling dasar dan sering digunakan untuk mengukur sejauh mana model dapat memprediksi kelas yang benar dari keseluruhan data [25]. Akurasi dihitung dengan rumus:

$$Akurasi = \frac{Jumlah\ prediksi\ benar}{Total\ Prediksi} \quad (1)$$

Namun, meskipun akurasi memberikan gambaran umum yang berguna, metrik ini dapat memberikan gambaran yang menyesatkan jika distribusi kelas tidak seimbang. Oleh karena itu, untuk memberikan informasi yang lebih mendalam, precision dan recall juga digunakan. Precision mengukur proporsi prediksi positif yang benar [26], yaitu seberapa banyak dari prediksi yang mengidentifikasi sepeda motor atau mobil yang benar-benar sesuai dengan kelas tersebut. Precision dihitung dengan rumus:

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives} \quad (2)$$

Di sisi lain, recall mengukur seberapa baik model dapat menangkap seluruh data yang benar-benar positif [27] (seperti semua gambar sepeda motor yang ada). Recall dihitung dengan rumus:

$$Recall = \frac{True\ Positives}{True\ Positives + False\ Negatives} \quad (4)$$

Kedua metrik ini memberikan informasi penting ketika kita ingin memahami trade-off antara kemampuan model dalam mengenali data positif dan menghindari kesalahan klasifikasi. Untuk memberikan gambaran yang lebih lengkap, F1-score dihitung sebagai rata-rata harmonis dari precision dan recall, memberikan keseimbangan antara keduanya [28]. F1-score dihitung dengan rumus:

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

Metrik terakhir yang digunakan adalah confusion matrix, yang merupakan representasi matriks dari hasil prediksi model [29], menggambarkan jumlah prediksi yang benar dan salah pada setiap kelas. Confusion matrix memberikan wawasan lebih lanjut tentang jenis kesalahan yang dilakukan model, apakah lebih cenderung mengklasifikasikan gambar mobil sebagai sepeda motor, atau sebaliknya. Matriks ini juga digunakan untuk menghitung true positives (TP), true negatives (TN), false positives (FP), dan false negatives (FN) yang menjadi dasar perhitungan precision, recall, dan F1-score.


Dengan menggunakan metrik-metrik tersebut, penilaian kinerja model tidak hanya mencakup seberapa akurat model dalam memprediksi kelas, tetapi juga memberikan wawasan tentang seberapa baik model menangani ketidakseimbangan kelas dan bagaimana model mengelola trade-off antara precision dan recall, yang sangat penting dalam aplikasi klasifikasi gambar

3. HASIL DAN PEMBAHASAN

Penelitian ini memanfaatkan dataset Car vs Bike dari Kaggle (Utkarsh Saxena, 2023) [12], yang terdiri dari 2.000 gambar sepeda motor dan 2.000 gambar mobil. Dataset ini dibagi untuk keperluan pelatihan dan validasi. Tiga model Convolutional Neural Network (CNN), yaitu EfficientNet, VGG16, dan ResNet50, diterapkan menggunakan pendekatan transfer learning dengan bobot pretrained dari ImageNet. Setiap model dilatih untuk mengklasifikasikan dua kategori utama, yaitu mobil dan sepeda motor, dengan hasil yang dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score

3.1 EfficientNet

Model EfficientNet telah dilatih dan divalidasi pada dataset "Car vs Bike," yang terdiri dari dua kelas utama, yaitu Bike dan Car. Berdasarkan evaluasi terhadap 400 sampel untuk masing-masing kelas, model ini menunjukkan performa yang tidak seimbang. Pada kelas Bike, model mencatatkan precision sebesar 0,50, recall sebesar 1,00, dan F1-score sebesar 0,67. Namun, pada kelas Car, model ini tidak dapat mengenali gambar Car sama sekali, dengan nilai precision, recall, dan F1-score masing-masing sebesar 0,00. Akurasi keseluruhan model tercatat sebesar 0,50. Selain itu, rata-rata makro (macro average) untuk precision, recall, dan F1-score masing-masing tercatat sebesar 0,25, 0,50, dan 0,33. Rata-rata berbobot (weighted average) untuk metrik yang sama juga mencapai nilai yang identik. Proses pelatihan dan validasi untuk model ini membutuhkan waktu total 1831,37 detik. Hasil evaluasi model EfficientNet menunjukkan bias signifikan terhadap kelas 'Bike,' seperti yang terlihat pada confusion matrix pada Gambar 2 berikut.




Gambar 2. Confussion Matriks Model EfficientNet

Confusion matrix model EfficientNet menunjukkan bahwa model cenderung bias terhadap kelas Bike. True Positives (TP) menunjukkan jumlah gambar yang benar diklasifikasikan sesuai dengan kelasnya, di mana seluruh 400 gambar Bike diklasifikasikan dengan benar sebagai Bike. Namun, model tidak mampu mengenali kelas Car sama sekali. False Positives (FP) menunjukkan bahwa 400 gambar Car salah diklasifikasikan sebagai Bike, sementara True Negatives (TN) untuk kelas Car adalah 0, menunjukkan tidak ada gambar Car yang diklasifikasikan dengan benar. False Negatives (FN) untuk kelas Bike juga tercatat sebagai 0, karena semua gambar Bike dikenali oleh model. Hasil ini mengindikasikan bahwa model hanya dapat mengenali kelas Bike tetapi gagal sepenuhnya dalam mengenali kelas Car.

3.2 VGG16

Model VGG16 juga dilatih dan divalidasi pada dataset "Car vs Bike," yang terdiri dari dua kelas utama, yaitu Bike dan Car. Berdasarkan evaluasi terhadap 400 sampel untuk masing-masing kelas, model ini menunjukkan hasil yang konsisten pada kedua kelas. Secara keseluruhan, model mencatatkan precision, recall, dan F1-score rata-rata sebesar 0,95 untuk kedua kelas. Akurasi keseluruhan model tercatat sebesar 0,95, menunjukkan kemampuan yang baik dalam mengklasifikasikan gambar ke dalam kedua kelas. Selain itu, rata-rata makro (macro average) dan rata-rata berbobot (weighted average) untuk precision, recall, dan F1-score juga mencapai nilai yang sama, yaitu 0,95. Proses pelatihan dan validasi membutuhkan waktu total 9280,02 detik. Confusion matrix pada Gambar 3 menunjukkan bahwa model ini memiliki kemampuan tinggi dalam mengenali baik kelas 'Bike' maupun 'Car'.




Gambar 3. Confussion Matriks Model VGG16

Confusion matrix model VGG16 memberikan gambaran rinci mengenai distribusi hasil klasifikasi. True Positives (TP) menunjukkan jumlah gambar yang diklasifikasikan dengan benar sebagai kelas yang sesuai. Dalam hal ini, sebanyak 377 gambar Bike diklasifikasikan dengan benar sebagai Bike, sedangkan True Negatives (TN) mencatat 383 gambar Car diklasifikasikan dengan benar sebagai Car. Sebaliknya, False Positives (FP) menunjukkan jumlah gambar yang salah diklasifikasikan sebagai kelas lain, yaitu 17 gambar Car salah diklasifikasikan sebagai Bike. False Negatives (FN) menunjukkan jumlah gambar yang gagal dikenali sebagai kelas yang benar, yaitu 23 gambar Bike salah diklasifikasikan sebagai Car. Informasi ini memberikan wawasan lebih mendalam mengenai bagaimana model VGG16 menangani tugas klasifikasi dan jenis kesalahan yang dibuat.

3.3 RestNet50

Model ResNet50 dilatih dan divalidasi pada dataset "Car vs Bike," yang terdiri dari dua kelas utama, yaitu Bike dan Car. Berdasarkan evaluasi terhadap 400 sampel untuk masing-masing kelas, pada kelas Bike, model mencatatkan precision sebesar 0,77, recall sebesar 0,59, dan F1-score sebesar 0,67. Sementara itu, pada kelas Car, model memperoleh precision sebesar 0,67, recall sebesar 0,82, dan F1-score sebesar 0,74. Secara keseluruhan, akurasi model tercatat sebesar 0,71. Selain itu, rata-rata makro (macro average) untuk precision, recall, dan F1-score masing-masing adalah 0,72, 0,71, dan 0,70, sementara rata-rata berbobot (weighted average) untuk metrik yang sama juga mencapai nilai yang serupa. Proses pelatihan dan validasi membutuhkan waktu total 3166,29 detik. Confusion matrix pada Gambar 4 memberikan detail lebih lanjut mengenai kesalahan klasifikasi, yang didominasi oleh misprediksi kelas 'Bike.'



Gambar 4. Confussion Matriks Model RestNet50

Confusion matrix model ResNet50 memberikan gambaran rinci mengenai distribusi hasil klasifikasi. True Positives (TP) menunjukkan jumlah gambar yang diklasifikasikan dengan benar sebagai kelas yang sesuai. Dalam hal ini, sebanyak 235 gambar Bike diklasifikasikan dengan benar sebagai Bike. True Negatives (TN) menunjukkan jumlah gambar yang diklasifikasikan dengan benar bukan kelas tersebut, di mana sebanyak 330 gambar Car diklasifikasikan dengan benar sebagai Car.

Sebaliknya, False Positives (FP) menunjukkan jumlah gambar yang salah diklasifikasikan sebagai kelas lain, misalnya 70 gambar Car salah diklasifikasikan sebagai Bike. False Negatives (FN) menunjukkan gambar yang gagal dikenali sebagai kelas yang benar, yaitu 165 gambar Bike salah diklasifikasikan sebagai Car. Informasi ini penting untuk menganalisis kekuatan dan kelemahan model dalam mengenali pola dari masing-masing kelas.

Tabel 1 berikut merangkum perbandingan kinerja tiga model, yaitu EfficientNet, VGG16, dan ResNet50, pada data validasi. Setiap metrik evaluasi, seperti precision, recall, F1-score, dan akurasi, dicantumkan untuk memberikan gambaran yang jelas mengenai kekuatan dan kelemahan masing-masing model dalam mengklasifikasikan dua kelas, 'Bike' dan 'Car'.

Tabel 1. Perbandingan Metrik Evaluasi

Model	Precision (Bike)	Recall (Bike)	F1-Score (Bike)	Precision (Car)	Recall (Car)	F1-Score (Car)	Accuracy
EfficientNet	0.50	1.00	0.67	0.00	0.00	0.00	0.50
VGG16	0.96	0.94	0.95	0.94	0.96	0.95	0.95
ResNet50	0.77	0.59	0.67	0.67	0.82	0.74	0.71

3.4 Pengujian dengan Data Uji

Pada tahap pengujian, dataset terpisah yang diperoleh melalui scraping menggunakan Bing Image Downloader digunakan untuk mengevaluasi performa ketiga model (EfficientNet, VGG16, dan ResNet50). Dataset pengujian ini terdiri dari dua kelas utama, yaitu Bike dan Car, dengan total sampel yang bervariasi pada setiap kelas. Pengujian

dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan data yang tidak terlihat selama pelatihan, dengan menggunakan metrik evaluasi seperti precision, recall, F1-score, dan akurasi.

Model EfficientNet mencatatkan precision sebesar 0,50, recall sebesar 1,00, dan F1-score sebesar 0,66 pada kelas Bike dengan 197 sampel. Namun, pada kelas Car, precision dan recall masing-masing adalah 0,00, dengan F1-score sebesar 0,00 dari total 199 sampel. Akurasi keseluruhan model tercatat sebesar 0,50. Rata-rata makro (macro average) untuk precision, recall, dan F1-score masing-masing adalah 0,25, 0,50, dan 0,33.


Model VGG16, pada dataset pengujian yang sama, mencatatkan precision sebesar 0,92, recall sebesar 1,00, dan F1-score sebesar 0,96 pada kelas Bike dengan 224 sampel. Untuk kelas Car, model ini mencatatkan precision sebesar 1,00, recall sebesar 0,91, dan F1-score sebesar 0,95 dengan 211 sampel. Akurasi keseluruhan model tercatat sebesar 0,96, dengan rata-rata makro untuk precision, recall, dan F1-score masing-masing sebesar 0,96, 0,95, dan 0,96.

Model ResNet50 mencatatkan precision sebesar 0,86, recall sebesar 0,90, dan F1-score sebesar 0,88 pada kelas Bike dengan 224 sampel. Pada kelas Car, model ini mencatatkan precision sebesar 0,89, recall sebesar 0,84, dan F1-score sebesar 0,87 dari total 211 sampel. Akurasi keseluruhan model tercatat sebesar 0,87, dengan rata-rata makro untuk precision, recall, dan F1-score masing-masing sebesar 0,87, 0,87, dan 0,87.

Tabel 2. Perbandingan Metrik Evaluasi Data Uji

Model	Precision (macro avg)	Recall (macro avg)	F1-Score (macro avg)	Accuracy
EfficientNet	0.25	0.50	0.33	0.50
VGG16	0.96	0.95	0.96	0.96
ResNet50	0.87	0.87	0.87	0.87

Pada Tabel 2 menampilkan performa tiga model pada dataset pengujian yang berbeda dari data pelatihan. Hasilnya menunjukkan bagaimana model mampu menggeneralisasi pada data baru, dengan metrik seperti precision, recall, F1-score, dan akurasi disajikan untuk setiap model.



Gambar 5. Grafik Perbandingan Metrik Evaluasi Data Validasi dan Data Uji

Grafik pada Gambar 5 memperlihatkan perbandingan kinerja model pada data validasi dan data uji, pada data validasi (grafik kiri), VGG16 menunjukkan performa terbaik di seluruh metrik evaluasi dengan skor mendekati 0,9 hingga lebih dari 0,95, jauh melampaui EfficientNet dan ResNet50. EfficientNet berada di posisi terendah dengan skor rata-rata di bawah 0,6 untuk seluruh metrik, sedangkan ResNet50 memiliki skor yang sedikit lebih baik dibandingkan EfficientNet, tetapi tidak signifikan.

Pada data uji (grafik kanan), tren serupa terlihat di mana VGG16 tetap menjadi model dengan performa terbaik, meskipun skor sedikit menurun dibandingkan data validasi, menunjukkan adanya perbedaan performa pada data yang belum dilihat model sebelumnya. ResNet50 masih memiliki skor yang lebih baik dibandingkan EfficientNet, tetapi gap antara keduanya lebih kecil dibandingkan pada data validasi. Hal ini menunjukkan bahwa VGG16 mampu menggeneralisasi lebih baik dibandingkan dua model lainnya.

3.5 Pembahasan

Penelitian ini mengevaluasi kinerja tiga model CNN, yaitu EfficientNet, VGG16, dan ResNet50, pada tugas klasifikasi kendaraan bermotor menggunakan dataset "Car vs Bike." Hasil menunjukkan bahwa VGG16 memiliki kinerja terbaik dengan akurasi, precision, recall, dan F1-score yang konsisten tinggi, baik pada dataset pelatihan/validasi maupun pengujian. Model ini mencatatkan akurasi keseluruhan sebesar 95%, dengan kemampuan yang seimbang dalam mengenali kedua kelas. ResNet50, meskipun berada di bawah VGG16, menunjukkan hasil yang cukup stabil dengan akurasi sebesar 71% pada dataset pelatihan/validasi dan 87% pada dataset pengujian. Sebaliknya, EfficientNet menampilkan performa yang sangat rendah, terutama pada kelas "Car," dengan akurasi keseluruhan hanya mencapai 50%. Performa berbeda antara dataset pelatihan/validasi dan pengujian mengindikasikan adanya variasi kemampuan model dalam menangani data baru.

EfficientNet menunjukkan efisiensi komputasi yang tinggi dengan waktu pelatihan relatif singkat. Namun, model ini gagal mengenali kelas "Car," yang terlihat dari precision dan recall sebesar 0,0 pada kelas tersebut. VGG16, meskipun memerlukan waktu pelatihan lebih lama, memberikan hasil terbaik dengan akurasi dan presisi yang tinggi secara konsisten. Hal ini menjadikannya pilihan yang kuat untuk aplikasi yang memerlukan akurasi tinggi meski dengan biaya komputasi lebih besar. Sementara itu, ResNet50 menawarkan kompromi yang menarik antara akurasi dan efisiensi. Dengan pendekatan residual learning, model ini mampu menangani kedalaman jaringan lebih baik daripada EfficientNet, meskipun akurasinya masih berada di bawah VGG16.

Kompleksitas arsitektur memiliki dampak signifikan terhadap kinerja model. Pendekatan residual learning pada ResNet50 memungkinkan model memanfaatkan jaringan yang lebih dalam tanpa kehilangan gradien, memberikan hasil yang lebih stabil dibandingkan EfficientNet. Di sisi lain, trade-off antara efisiensi dan akurasi juga terlihat jelas; VGG16 unggul dalam akurasi tetapi membutuhkan waktu pelatihan yang lebih panjang, sementara EfficientNet mengutamakan efisiensi dengan mengorbankan kemampuan generalisasi pada kelas tertentu. Selain itu, bias pada dataset terhadap kelas "Bike" kemungkinan besar memengaruhi performa EfficientNet, yang terlihat lebih mudah mengenali gambar kelas tersebut dibandingkan kelas "Car."

Penelitian ini menawarkan kontribusi unik dalam membandingkan tiga model CNN, yaitu EfficientNet, VGG16, dan ResNet50, dalam tugas klasifikasi kendaraan bermotor. Hasil yang diperoleh menunjukkan bahwa VGG16 unggul secara konsisten, sementara ResNet50 memberikan keseimbangan antara akurasi dan efisiensi, dan EfficientNet menunjukkan kelemahan signifikan dalam mengenali kelas "Car." Temuan ini sejalan dengan studi sebelumnya oleh Kujur et al. (2022)[11], yang menyoroti bahwa performa model CNN sangat bergantung pada kompleksitas data dan distribusi kelas. Dalam konteks ini, bias dataset yang cenderung mendukung kelas "Bike" menjadi faktor yang memperkuat hasil rendah dari EfficientNet.

Studi lain, seperti yang dilakukan oleh Tas et al. (2022)[8], menunjukkan tantangan model CNN dalam menangani citra berkualitas rendah, yang relevan dengan hasil penelitian ini. Performa rendah EfficientNet pada kelas "Car" dapat dikaitkan dengan ketidakseimbangan kualitas data atau variasi dalam citra kelas tersebut. Di sisi lain, hasil VGG16 yang unggul mendukung temuan Chow et al. (2023)[9], yang menyebutkan bahwa model ini sangat efektif dalam tugas klasifikasi citra medis, bahkan pada dataset yang kompleks.

Namun, berbeda dari penelitian sebelumnya yang cenderung fokus pada domain seperti citra medis [9] atau citra berkualitas rendah [8], penelitian ini secara langsung menguji performa model pada domain kendaraan bermotor, yang lebih spesifik dan relevan dengan aplikasi transportasi cerdas. Dengan demikian, hasil penelitian ini memperluas pemahaman tentang keunggulan dan kelemahan model CNN dalam konteks yang lebih praktis, memberikan kontribusi baru terhadap literatur yang ada. Hal ini juga menegaskan perlunya penelitian lanjutan yang menggunakan dataset lebih kompleks untuk menggali lebih dalam performa model-model ini di domain spesifik.

Hasil penelitian ini memiliki relevansi langsung dengan aplikasi dunia nyata, seperti sistem transportasi cerdas yang membutuhkan deteksi kendaraan secara cepat dan akurat dalam berbagai kondisi lingkungan. Kinerja VGG16 yang konsisten menunjukkan potensinya untuk diterapkan pada tugas yang memerlukan klasifikasi citra presisi tinggi. ResNet50, dengan komprominya antara akurasi dan efisiensi, dapat menjadi pilihan yang baik untuk aplikasi yang memerlukan keseimbangan antara kedua aspek tersebut. Di sisi lain, hasil yang kurang memuaskan dari EfficientNet menunjukkan perlunya pengoptimalan lebih lanjut sebelum dapat digunakan dalam konteks serupa.

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Penggunaan dataset dengan hanya dua kelas (Car vs Bike) tidak mencerminkan keragaman sebenarnya dalam klasifikasi kendaraan bermotor, seperti truk, bus, atau kendaraan lain. Selain itu, ketergantungan pada transfer learning dari ImageNet dapat menjadi kurang optimal untuk domain spesifik kendaraan bermotor, karena fitur yang dipelajari pada dataset umum mungkin tidak sepenuhnya relevan dengan klasifikasi kendaraan.

4. KESIMPULAN

Penelitian ini membandingkan kinerja tiga model CNN, yaitu EfficientNet, VGG16, dan ResNet50, untuk tugas klasifikasi kendaraan bermotor menggunakan dataset "Car vs Bike." Hasil menunjukkan bahwa VGG16 memberikan kinerja terbaik dengan akurasi 95% dan kemampuan yang seimbang dalam mengenali kedua kelas. ResNet50 berada di peringkat kedua, dengan akurasi 71% pada pelatihan/validasi dan 87% pada pengujian, menunjukkan keseimbangan antara akurasi dan efisiensi komputasi. Di sisi lain, EfficientNet menunjukkan kelemahan signifikan, dengan akurasi keseluruhan hanya 50% dan bias terhadap kelas "Bike," yang kemungkinan besar disebabkan oleh bias dataset dan keterbatasan kemampuan generalisasi model ini dalam tugas spesifik. Hasil ini juga memperkuat temuan dalam penelitian sebelumnya yang menunjukkan pentingnya desain arsitektur jaringan dan kualitas data terhadap kinerja model. Pendekatan residual learning pada ResNet50 terbukti memberikan stabilitas performa, sedangkan keunggulan VGG16 dalam mengekstraksi fitur mendalam memungkinkan akurasi tinggi pada dataset dengan distribusi seimbang. Sebaliknya, efisiensi komputasi pada EfficientNet belum cukup untuk mengimbangi kebutuhan akurasi dalam domain spesifik ini. Penelitian ini memiliki beberapa keterbatasan, termasuk penggunaan dataset dua kelas dan ketergantungan pada transfer learning dari ImageNet. Untuk meningkatkan relevansi, disarankan menggunakan dataset dengan lebih banyak kelas dan variasi serta mengeksplorasi teknik fine-tuning lebih lanjut. Temuan ini memberikan wawasan penting untuk pengembangan sistem klasifikasi kendaraan bermotor yang lebih andal dalam aplikasi dunia nyata.

REFERENCES

- [1] Y. Bi, B. Xue, and M. Zhang, "Genetic Programming With a New Representation to Automatically Learn Features and Evolve Ensembles for Image Classification," *Ieee Trans. Cybern.*, vol. 51, no. 4, pp. 1769–1783, 2021, doi: 10.1109/tcyb.2020.2964566.
- [2] J. Moon and S. Park, "Robust Visual Detection of Brake-Lights in Front for Commercialized Dashboard Camera," *PLoS One*, vol. 18, no. 8, p. e0289700, 2023, doi: 10.1371/journal.pone.0289700.
- [3] C. Shekhar and S. Saha, "Real Time Vehicle Identification," 2022, doi: 10.48550/arxiv.2207.08081.
- [4] N. S. S. Pal, P. Raymahapatra, S. Paul, S. Dolui, A. K. Chaudhuri, and S. Das, "A Novel Brain Tumor Classification Model Using Machine Learning Techniques," *Int. J. Eng. Technol. Manag. Sci.*, vol. 7, no. 2, pp. 87–98, 2023, doi: 10.46647/ijetms.2023.v07i02.011.
- [5] A. Mirzazadeh, A. Azizi, Y. Abbaspour-Gilandeh, J. L. Hernández-Hernández, M. Hernández-Hernández, and I. Gallardo-Bernal, "A Novel Technique for Classifying Bird Damage to Rapeseed Plants Based on a Deep Learning Algorithm," *Agronomy*, vol. 11, no. 11, p. 2364, 2021, doi: 10.3390/agronomy11112364.
- [6] A. Wongpanich *et al.*, "Training EfficientNets at Supercomputer Scale: 83% ImageNet Top-1 Accuracy in One Hour," 2020, doi: 10.48550/arxiv.2011.00071.
- [7] M. A. Hafeez, A. Munir, and H. Ullah, "H-QNN: A Hybrid Quantum–Classical Neural Network for Improved Binary Image Classification," *Ai*, vol. 5, no. 3, pp. 1462–1481, 2024, doi: 10.3390/ai5030070.
- [8] S. Tas, O. Sari, Y. Dalveren, S. Pazar, A. Kara, and M. Derawi, "Deep Learning-Based Vehicle Classification for Low Quality Images," *Sensors*, vol. 22, no. 13, p. 4740, 2022, doi: 10.3390/s22134740.
- [9] L. S. Chow, G. S. Tang, M. I. Solihin, N. M. Gowdh, N. Ramli, and K. Rahmat, "Quantitative and Qualitative Analysis of 18 Deep Convolutional Neural Network (CNN) Models With Transfer Learning to Diagnose COVID-19 on Chest X-Ray (CXR) Images," *Sn Comput. Sci.*, vol. 4, no. 2, 2023, doi: 10.1007/s42979-022-01545-8.
- [10] J. Cao, C. Wu, L. Chen, H. Cui, and F. Guo, "An Improved Convolutional Neural Network Algorithm and Its Application in Multilabel Image Labeling," *Comput. Intell. Neurosci.*, vol. 2019, pp. 1–12, 2019, doi: 10.1155/2019/2060796.
- [11] A. Kujur, Z. Raza, A. A. Khan, and C. Wechtaisong, "Data Complexity Based Evaluation of the Model Dependence of Brain MRI Images for Classification of Brain Tumor and Alzheimer's Disease," *Ieee Access*, vol. 10, pp. 112117–112133, 2022, doi: 10.1109/access.2022.3216393.
- [12] U. Saxena, "Car vs Bike Classification Dataset." 2023. [Online]. Available: <https://www.kaggle.com/datasets/utkarshsaxenadn/car-vs-bike-classification-dataset/data>
- [13] N. Zakaria, "Improved Image Classification Task Using Enhanced Visual Geometry Group of Convolution Neural Networks," *Joiv Int. J. Informatics Vis.*, vol. 7, no. 4, p. 2498, 2023, doi: 10.30630/joiv.7.4.01752.
- [14] N. Islam *et al.*, "Diagnosis of Hearing Deficiency Using EEG Based AEP Signals: CWT and Improved-Vgg16 Pipeline," *Peerj Comput. Sci.*, vol. 7, p. e638, 2021, doi: 10.7717/peerj-cs.638.
- [15] S. Kundu, M. Nazemi, M. Pedram, K. M. Chugg, and P. A. Beerel, "Pre-Defined Sparsity for Low-Complexity Convolutional Neural Networks," *Ieee Trans. Comput.*, p. 1, 2020, doi: 10.1109/tc.2020.2972520.
- [16] P. Sudhakar, "Novel Skin Cancer Detection Based Transfer Learning With Optimization Algorithm Using Dermatology Dataset," *Eai Endorsed Trans. Pervasive Heal. Technol.*, vol. 9, 2023, doi: 10.4108/eetpht.9.4.277.
- [17] R. Mohan, K. Ganapathy, and A. Rama, "Brain Tumour Classification of Magnetic Resonance Images Using a Novel CNN Based Medical Image Analysis and Detection Network in Comparison With VGG16," *JPTCP*, vol. 28, no. 2, 2022, doi: 10.47750/jptcp.2022.873.
- [18] F. Yi *et al.*, "Dual Model Medical Invoices Recognition," *Sensors*, vol. 19, no. 20, p. 4370, 2019, doi: 10.3390/s19204370.
- [19] P. Alkhairi and A. P. Windarto, "Classification Analysis of Back Propagation–Optimized CNN Performance in Image Processing," *J. Syst. Eng. Inf. Technol.*, vol. 2, no. 1, 2023, doi: 10.29207/joseit.v2i1.5015.
- [20] S. K. Lee *et al.*, "Rapid and Concise Quantification of Mycelial Growth by Microscopic Image Intensity Model and Application to Mass Cultivation of Fungi," *Scientific Reports*. 2021. doi: 10.1038/s41598-021-03512-4.
- [21] D. Varshni, K. Thakral, L. Agarwal, R. Nijhawan, and A. Mittal, "Pneumonia Detection Using CNN Based Feature Extraction," pp. 1–7, 2019, doi: 10.1109/icecct.2019.8869364.
- [22] S. Sumera, R. Sirisha, N. Anjum, and K. Vaidehi, "Implementation of CNN and ANN for Fashion-Mnist-Dataset Using Different Optimizers," *Indian J. Sci. Technol.*, vol. 15, no. 47, pp. 2639–2645, 2022, doi: 10.17485/ijst/v15i47.1821.
- [23] R. Amalia and F. Panjaitan, "Mask Detection Using Convolutional Neural Network Algorithm," *J. Resti (Rekayasa Sist. Dan Teknol. Informasi)*, vol. 6, no. 4, pp. 639–647, 2022, doi: 10.29207/resti.v6i4.4276.
- [24] R. y. Adhitya, "Rancang Bangun Aplikasi Intelligent Visual Scanner Berbasis CNN Untuk Identifikasi Cacat Pada Hasil Pengelasan," *J. Comput. Electron. Telecommun.*, vol. 4, no. 2, 2023, doi: 10.52435/complete.v4i2.393.
- [25] N. Firdausy, "Analisis Sentimen Evaluasi Reaksi E-Learning Menggunakan Algoritma Naïve Bayes, Support Vector Machine Dan Deep Learning," *Techno Com*, vol. 22, no. 3, pp. 677–689, 2023, doi: 10.33633/tc.v22i3.8160.
- [26] V. A. Saputra, "Penerapan Metode Machine Learning Dalam Mengidentifikasi Berita Hoaks," *Comput. Based Inf. Syst. J.*, vol. 12, no. 1, pp. 112–121, 2024, doi: 10.33884/cbis.v12i1.8442.
- [27] A. F. Hanif, "Perbandingan Kinerja LSTM, Bi-Lstm, Dan GRU Pada Klasifikasi Judul Berita Clickbait," *Indones. J. Comput. Sci.*, vol. 12, no. 4, 2023, doi: 10.33022/ijcs.v12i4.3281.
- [28] R. I. Arumnisaa and A. W. Wijayanto, "Comparison of Ensemble Learning Method: Random Forest, Support Vector Machine, AdaBoost for Classification Human Development Index (HDI)," *Sistemasi*, vol. 12, no. 1, p. 206, 2023, doi: 10.32520/stmsi.v12i1.2501.
- [29] B. Imran, "Klasifikasi Berita Hoax Terkait Pemilihan Umum Presiden Republik Indonesia Tahun 2024 Menggunakan Naïve Bayes Dan SVM," *Din. Rekayasa*, vol. 20, no. 1, pp. 1–9, 2024, doi: 10.20884/1.dinarek.2024.20.1.27.