

Implementasi Arsitektur MobileNetV2 dengan Metode Transfer Learning untuk Identifikasi Objek Wisata Religi

Nabilah Putri Wijaya*, Bernadus Very Christioko

Fakultas Teknologi Informasi dan Komunikasi, Program Studi Teknik Informatika, Universitas Semarang, Semarang, Indonesia

Email: ^{1,*}nabilahputriwijaya@gmail.com, ²very@usm.ac.id

Email Penulis Korespondensi: nabilahputriwijaya@gmail.com

Submitted: 01/10/2025; Accepted: 06/12/2025; Published: 08/12/2025

Abstrak—Kota Semarang memiliki lima ikon wisata religi yang merepresentasikan pluralisme, namun promosinya masih konvensional dan belum optimal di era digital. Masalah ini menghambat potensi pariwisatanya dalam menjangkau *audiens* yang lebih luas. Penelitian ini bertujuan untuk mengembangkan sebuah model identifikasi citra otomatis yang akurat dan efisien sebagai solusi modern untuk tantangan promosi tersebut. Metode yang diimplementasikan adalah deep learning dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) MobileNetV2 melalui pendekatan transfer learning. MobileNetV2 dipilih karena lebih unggul dalam efisiensi komputasi pada perangkat dengan sumber daya terbatas dibandingkan dengan model lain seperti EfficientNet. Model dilatih dan divalidasi menggunakan dataset gambar yang berjumlah total 7500 gambar terdiri dari 5 kelas objek wisata religi yaitu Masjid Agung Jawa Tengah, Gereja Blenduk, Wihara Buddhagaya Watugong, Pura Agung Giri Natha, dan Klenteng Sam Poo Kong. Dataset dibagi dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji. Hasil evaluasi pada data uji menunjukkan kinerja yang sangat memuaskan, di mana model yang dikembangkan berhasil mencapai akurasi keseluruhan sebesar 98%, dengan nilai *macro average* F1-Score juga sebesar 0.98. Angka ini menandakan performa yang tinggi dan seimbang di semua kelas. Pengujian individual juga membuktikan kemampuan model untuk mengenali gambar relevan dengan keyakinan tinggi serta menolak gambar di luar kelas. Keberhasilan ini menunjukkan bahwa implementasi MobileNetV2 sangat efektif dan dapat menjadi teknologi dasar untuk pengembangan aplikasi pariwisata digital inovatif di Kota Semarang.

Kata Kunci: Deep Learning; Klasifikasi Gambar; MobileNetV2; Transfer Learning; Wisata Religi

Abstract—Semarang has five religious tourism icons that represent pluralism, but their promotion is still conventional and not yet optimal in the digital era. This problem hinders its tourism potential in reaching a wider audience. This study aims to develop an accurate and efficient automatic image identification model as a modern solution to these promotional challenges. The method implemented is deep learning using the MobileNetV2 CNN architecture through a transfer learning approach. MobileNetV2 was chosen because it is superior in computational efficiency on resource-constrained devices compared to other models like EfficientNet. The model was trained and validated using a dataset consisting of a total of 7,500 images comprising five classes of religious tourist attractions, namely Grand Mosque of Central Java, Blenduk Church, Buddhagaya Watugong Temple, Pura Agung Giri Natha Temple, and Sam Poo Kong Temple. The dataset was divided into 70% training data, 15% validation data, and 15% test data. The evaluation results on the test data showed satisfactory performance, where the developed model achieved an overall accuracy of 98%, with a macro average F1-Score of 0.98. This figure indicates high and balanced performance across all classes. Individual testing also proved the model's ability to recognize relevant images with high confidence and reject images outside the class. This success shows that the implementation of MobileNetV2 is effective and can be basic technology for development of innovative digital tourism applications in Semarang.

Keywords: Deep Learning; Image Classification; MobileNetV2; Religious Tourism; Transfer Learning

1. PENDAHULUAN

Kota Semarang memiliki identitas unik sebagai cerminan kerukunan dan pluralisme di Indonesia. Keunikan ini terefleksi secara nyata melalui keberadaan lima ikon wisata religi yang merepresentasikan agama-agama besar, yaitu Masjid Agung Jawa Tengah (Islam), Gereja Blenduk (Kristen Protestan), Wihara Buddhagaya Watugong (Buddha), Pura Agung Giri Natha (Hindu), dan Klenteng Sam Poo Kong (Tridharma/Konghucu). Keberadaan situs-situs ini dalam satu lanskap kota tidak hanya menjadi aset pariwisata, tetapi juga simbol harmoni keagamaan yang menjadi daya tarik utama [1].

Meskipun memiliki aset multikultural yang tak ternilai ini, masalah utama yang dihadapi adalah potensi pariwisatanya belum tergarap secara optimal di ranah digital. [2]. Hal ini diperkuat oleh fakta bahwa metode promosi yang berjalan saat ini masih cenderung konvensional dan sangat bergantung pada strategi getok tular atau dari mulut ke mulut, yang dinilai tidak lagi memadai untuk bersaing di era digital, seperti yang disebutkan dalam laman berita suaramerdeka.com di tahun 2023 yang berjudul "MTC Jateng : Promosi Wisata Religi Harus Diubah, Jangan Hanya Getok Tular" [3], sebuah pendekatan yang dinilai tidak lagi memadai untuk bersaing di era digital yang sangat dipengaruhi oleh konten visual di media sosial [4]. Oleh karena itu, diperlukan sebuah solusi berbasis teknologi untuk beralih dari model promosi pasif ke strategi yang lebih proaktif dan menarik secara visual.

Beberapa strategi yang lebih proaktif untuk melakukan klasifikasi gambar objek wisata telah dilakukan di berbagai penelitian sebelumnya. Beberapa peneliti menerapkan arsitektur CNN yang berbeda untuk objek di Jawa Tengah. Misalnya Mira, dkk. pada tahun 2022 menggunakan ResNet-50 untuk klasifikasi objek wisata secara umum dengan akurasi 88,52%, dan Adithama, dkk. di tahun 2023 yang berhasil mengidentifikasi batik Jawa Tengah menggunakan VGG16 dengan akurasi 92% [5], [6]. Selain untuk klasifikasi, penelitian oleh Jha & Bhaduar tahun 2023 juga menunjukkan potensi *deep learning* dalam pengambilan citra monumen bersejarah secara efisien dengan

akurasi mencapai 99,63% [7]. Ditinjau dari beberapa penelitian sebelumnya, teknologi pendekatan *deep learning* dengan metode *transfer learning* telah terbukti efektif untuk klasifikasi gambar objek budaya dan pariwisata.

Kemajuan terbaru dalam algoritma *deep learning* dengan metode *transfer learning* menawarkan solusi untuk klasifikasi gambar dengan berbagai arsitektur. Salah satu arsitektur yang ada yaitu MobileNetV2, seperti yang sudah dilakukan oleh Saputra, dkk. di tahun 2022 untuk mengklasifikasikan senjata tradisional di Jawa Tengah dan berhasil mencapai akurasi sangat tinggi sebesar 98,64% [8]. Arsitektur MobileNetV2 secara konsisten menunjukkan performa yang unggul sebagai model klasifikasi citra yang ringan namun akurat. Keefektifan model ini, terutama ketika diimplementasikan dengan metode *transfer learning*, telah terbukti di berbagai domain penelitian. Seperti yang ditunjukkan pada penelitian oleh Gulzar (2023)[9] berhasil mencapai akurasi luar biasa sebesar 99% dalam tugas klasifikasi buah dan secara kuantitatif mengungguli arsitektur lain yang lebih kompleks seperti VGG16 dan ResNet. Dukungan terhadap performa tinggi ini juga terlihat pada penelitian Kazi (2024) [10] yang memperoleh akurasi 97,16% pada klasifikasi makanan, serta penelitian Singh, dkk. (2024) [11] yang mencapai akurasi 98,66% dalam diagnosis penyakit jeruk. Kemampuan adaptasi MobileNetV2 pada dataset yang lebih menantang juga ditunjukkan dalam penelitian oleh Wang, dkk. (2023) [12] mengintegrasikan arsitektur ini dengan Generative Adversarial Networks (GANs) untuk mengatasi masalah ketidakseimbangan data pada klasifikasi lesi kulit. Meskipun akurasinya berada di angka 87,07%, penelitian ini membuktikan bahwa arsitektur MobileNetV2 dapat menjadi dasar yang kuat untuk dimodifikasi dan diterapkan pada kasus-kasus kompleks seperti pencitraan medis. Aspek fundamental yang menjadi keunggulan utama MobileNetV2 adalah keseimbangan antara akurasi dan efisiensi komputasi. Hal ini secara eksplisit dibuktikan oleh Jain, dkk. (2024) [13], yang dalam studi komparatifnya dengan EfficientNet menyimpulkan bahwa MobileNetV2 adalah pilihan superior untuk aplikasi pada perangkat dengan sumber daya terbatas. Dari penelitian tersebut mengonfirmasi bahwa MobileNetV2 merupakan arsitektur yang sangat relevan dan andal untuk pengembangan sistem identifikasi citra yang membutuhkan akurasi tinggi dengan tetap mempertahankan efisiensi komputasi.

Sebagai jawaban atas tantangan promosi wisata religi di Semarang dengan strategi yang lebih proaktif dan menarik secara visual, penelitian ini mengusulkan penerapan teknologi *deep learning* di bidang *computer vision*. Secara spesifik, penelitian ini mengimplementasikan arsitektur Convolutional Neural Network (CNN), yaitu MobileNetV2, yang dikombinasikan dengan metode *transfer learning*. Pendekatan ini dipilih karena memiliki beberapa keunggulan signifikan. Arsitektur MobileNetV2 dikenal memiliki efisiensi komputasi yang tinggi, yang membuatnya sangat ideal untuk aplikasi pada perangkat seluler dengan sumber daya terbatas [13]. Di sisi lain, metode *transfer learning* memungkinkan model untuk mencapai akurasi tinggi dalam mengenali fitur-fitur unik dari kelima objek wisata religi tanpa memerlukan puluhan ribu gambar untuk pelatihan dari awal [14], [15]. Penerapan gabungan teknologi ini sejalan dengan penelitian sebelumnya yang membuktikan bahwa pengenalan gambar otomatis mampu meningkatkan akurasi sistem rekomendasi pariwisata dan menyajikan informasi yang lebih personal kepada calon wisatawan [16], [17].

Meskipun keefektifan umum dari metode *transfer learning* CNN sudah terbukti untuk identifikasi objek budaya di Jawa Tengah, terdapat kesenjangan penelitian (*research gap*) yang jelas. Belum ada studi yang secara spesifik meneliti identifikasi otomatis kelima ikon wisata religi utama di Semarang sebagai sebuah dataset yang unik. Oleh karena itu, penerapan teknologi ini untuk mengenali objek-objek yang secara kolektif menjadi simbol harmoni dan pluralisme kota merupakan sebuah kebaruan yang belum dieksplorasi. Dengan kata lain, metode ini belum pernah dipakai untuk membangun model yang mampu menangkap dan merepresentasikan identitas multi-agama sebuah kota.

Berdasarkan kesenjangan tersebut, maka tujuan dari penelitian ini adalah untuk mengembangkan dan mengimplementasikan sebuah model klasifikasi gambar yang mampu mengidentifikasi kelima ikon wisata religi utama di Semarang secara cepat dan akurat menggunakan arsitektur MobileNetV2 dengan metode *transfer learning*. Harapan yang ingin dicapai adalah model yang dihasilkan dapat menjadi teknologi dasar bagi pengembangan aplikasi pariwisata digital yang inovatif di masa depan, seperti sistem rekomendasi cerdas, pemandu wisata virtual berbasis *augmented reality*, atau pengayaan konten pada *platform* media sosial. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam meningkatkan strategi promosi digital dan memperkuat citra Kota Semarang sebagai destinasi pariwisata religi yang unggul dan harmonis.

2. METODOLOGI PENELITIAN

Penelitian ini dimulai dengan pengumpulan data yang diperlukan. Data yang terkumpul kemudian diproses melalui *preprocessing* untuk mempersiapkan data sebelum digunakan dalam pembangunan model dengan metode *transfer learning*. Model yang telah dibangun selanjutnya menjalani tahap pelatihan untuk menyesuaikan parameter. Tahapan terakhir adalah evaluasi model untuk mengukur kinerja dan kemampuan generalisasi model menggunakan data uji. Diagram alur tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

Gambar 1 menunjukkan alur proses penelitian dimulai dari pengumpulan data, *preprocessing*, pembangunan dan pelatihan model, hingga evaluasi untuk mengukur kinerja model.

2.1 Pengumpulan Data

Pada penelitian ini langkah pertama yang dilakukan adalah pengumpulan data. Dataset yang diperlukan untuk digunakan dalam penelitian ini adalah kumpulan gambar-gambar dari 5 objek wisata religi yang ada di Semarang yaitu Wihara Buddhagaya Watugong, Masjid Agung Jawa Tengah, Pura Agung Giri Natha, Gereja Blenduk, dan Klenteng Sam Poo Kong. Data yang digunakan dalam penelitian ini berupa gambar yang diperoleh melalui dua cara, yaitu dokumentasi langsung di lapangan dan pengunduhan gambar dari Google Images. Dataset gambar yang berhasil di dapat yaitu Wihara Buddhagaya Watugong adalah 235 gambar, Masjid Agung Jawa Tengah 382 gambar, Pura Agung Giri Natha 261 gambar, Gereja Blenduk 304 gambar, dan Klenteng Sam Poo Kong 240 gambar. Kemudian diperbanyak jumlahnya dengan augmentasi sehingga berjumlah total 7500 gambar terdiri dari 5 kelas, masing-masing kelas memiliki 1500 gambar.

2.2 Preprocessing Data

Tahap *preprocessing* data merupakan langkah krusial dalam penelitian ini, dengan fokus utama pada penerapan teknik augmentasi gambar. Tujuan utamanya adalah untuk mengatasi masalah ketidakseimbangan data dengan meningkatkan jumlah sampel pada kelas yang memiliki gambar lebih sedikit [18], sekaligus untuk meningkatkan kemampuan generalisasi model dan mengurangi potensi bias [19]. Serangkaian teknik augmentasi yang diterapkan diuraikan sebagai berikut:

a. Transformasi Geometris *Horizontal Flip*

Salah satu teknik fundamental dalam augmentasi data adalah *horizontal flip*. Teknik *horizontal flip* adalah metode augmentasi data yang membalik gambar secara horizontal. Ini merupakan salah satu cara paling efektif untuk memperkaya variasi pada dataset latihan tanpa mengubah makna atau label dari gambar tersebut [20]. Manfaat utamanya adalah melatih model agar tidak kaku dan mampu mengenali sebuah objek dari berbagai perspektif, termasuk dalam orientasi cermin.

b. Rotasi

Teknik augmentasi rotasi memainkan peran penting dalam meningkatkan kemampuan generalisasi model. Rotasi membantu model belajar mengenali objek meskipun gambar diputar, meningkatkan fleksibilitas model dalam mendeteksi objek pada berbagai orientasi. Rotasi memperkenalkan variasi sudut pandang, melatih model untuk mengenali objek dalam berbagai orientasi [21].

c. *Random Brightness/Contrast*

Untuk melatih model agar andal dalam berbagai kondisi pencahayaan, Teknik *Random Brightness/Contrast* memodifikasi tingkat kecerahan (*brightness*) dan kontras (*contrast*) gambar secara acak. Langkah ini penting karena mensimulasikan variasi pencahayaan yang umum terjadi di dunia nyata, misalnya perbedaan antara siang yang cerah dan hari yang berawan. Hasilnya, model belajar untuk fokus pada fitur-fitur asli dari objek dan tidak terkecoh oleh perubahan cahaya, sehingga kinerjanya menjadi lebih tangguh dan akurat [21], [22].

d. *ShiftScaleRotate*

Salah satu teknik augmentasi yang sangat komprehensif adalah dengan menerapkan serangkaian transformasi geometris secara acak pada gambar. Teknik ini tidak hanya melakukan satu operasi, tetapi menggabungkan beberapa tindakan sekaligus yaitu gambar akan secara acak menggeser (*translasi*) posisinya, mengubah ukuran (*scaling*) untuk mensimulasikan efek (*zoom*) lebih dekat atau lebih jauh, dan memutar gambar pada sudut tertentu. Alasan utama di balik penerapan variasi acak ini adalah untuk meniru keragaman kondisi yang ditemukan dalam berbagai cara pengambilan foto di dunia nyata. Dalam skenario praktis, objek jarang difoto secara sempurna, terpusat, atau pada jarak yang konsisten. Dengan tujuan untuk melatih model agar lebih tangguh dalam mengenali objek dari berbagai sudut pandang dan jarak [21].

e. *Blur*

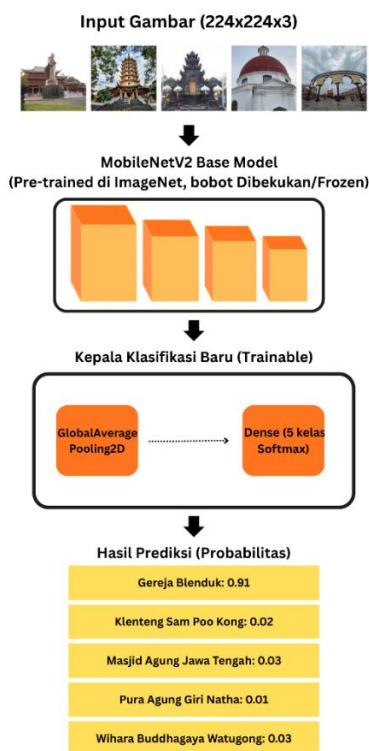
Penerapan efek kabur (*blur*) sebagai teknik augmentasi data memiliki tujuan strategis untuk meningkatkan ketangguhan model. Metode ini dirancang untuk melatih model agar dapat mengidentifikasi dan fokus pada fitur-fitur esensial atau karakteristik utama dari sebuah objek. Dengan sengaja mengurangi ketajaman gambar, model didorong untuk belajar mengabaikan detail-detail yang tidak relevan, seperti *noise* atau ketidaksempurnaan lain pada gambar. Teknik ini secara efektif mensimulasikan berbagai kondisi yang sering ditemui di dunia nyata, seperti foto yang diambil dalam kondisi di luar fokus (*out-of-focus*), atau gambar dengan kualitas keseluruhan yang rendah, yang mungkin disebabkan oleh guncangan kamera atau kompresi file yang buruk [21].

f. *Resize*

Sebagai langkah terakhir dan krusial dalam tahap *preprocessing* data, semua gambar dalam dataset, baik untuk pelatihan maupun validasi, diseragamkan ukurannya. Semua gambar diubah ukurannya menjadi 224x224 piksel. Langkah ini wajib dilakukan karena arsitektur MobileNetV2 secara spesifik membutuhkan ukuran input tersebut. Selain untuk memenuhi tuntutan arsitektur, penyeragaman ini juga membawa manfaat signifikan lainnya, yaitu memastikan proses belajar model menjadi lebih konsisten dan efisien. Dengan input yang seragam, model dapat memproses data dalam batch secara stabil [21].

2.3 Pembangunan Model

Alur pembangunan model, mulai dari input gambar hingga hasil prediksi probabilitas untuk masing-masing kelas ikon wisata religi digambarkan pada Gambar 2 berikut.



Gambar 2. Proses Transfer Learning dengan Arsitektur MobileNetV2 untuk Klasifikasi Objek Wisata Religi

Seperti pada Gambar 2, metode yang digunakan dalam penelitian ini adalah klasifikasi citra menggunakan arsitektur MobileNetV2 dengan pendekatan transfer learning. Model dasar MobileNetV2, yang telah dilatih pada dataset ImageNet, digunakan dengan menghapus lapisan klasifikasi aslinya (`include_top=False`). Kemudian, ditambahkan kepala klasifikasi baru yang terdiri dari lapisan `GlobalAveragePooling2D` dan `Dense` dengan fungsi aktivasi `softmax` untuk menghasilkan 5 kelas output [9], [23], [24]. Untuk menyesuaikan model dengan dataset penelitian, diterapkan strategi *fine-tuning*, di mana 30% lapisan awal *base model* dibekukan untuk mempertahankan fitur umum dari ImageNet, sementara lapisan lainnya tetap dapat dilatih. Strategi ini bertujuan untuk mengurangi *overfitting* dan meningkatkan kinerja model secara keseluruhan. [11], [25], [26].

2.4 Training Model

Model yang akan dilatih pada penelitian ini mengimplementasikan arsitektur MobileNetV2 yang diinisialisasi dengan bobot *pre-trained* dari imagenet dan dikonfigurasi untuk menerima *input* gambar berukuran $224 \times 224 \times 3$. Dalam penerapan *transfer learning*, 30% dari lapisan awal *base model* dibekukan agar bobotnya tidak diperbarui. Untuk proses kompilasi, model menggunakan *optimizer* Adam dengan *learning rate* sebesar 1×10^{-6} . Penggunaan *learning rate* yang rendah ini krusial dalam *fine-tuning* untuk memastikan penyesuaian bobot terjadi secara gradual. Fungsi *loss* yang dipilih adalah *categorical_crossentropy* dengan fungsi aktivasi `softmax` pada *layer output*, yang sesuai untuk tugas klasifikasi multi-kelas, dan kinerjanya dievaluasi menggunakan metrik *accuracy* [27].

Dataset dibagi dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji untuk memastikan model mampu melakukan generalisasi pada data baru [27]. Pelatihan berlangsung selama 20 *epoch* dengan *batch size* sebesar 64, konfigurasi ini dipilih karena *batch size* 64 terbukti memberikan keseimbangan antara efisiensi komputasi dan akurasi [28] [29]. Sementara 20 *epoch* dianggap memadai untuk mencapai konvergensi tanpa risiko *overfitting* yang signifikan [30], [31]. Seluruh tahapan penelitian, mulai dari *preprocessing data*, pelatihan model, hingga evaluasi, dieksekusi menggunakan platform Google Colaboratory. Lingkungan eksekusi atau *runtime* yang digunakan terhubung dengan *backend* Google Compute Engine yang telah dilengkapi GPU untuk proses komputasi *deep learning* yang intensif. Spesifikasi perangkat keras yang dialokasikan untuk lingkungan pelatihan ini mencakup 15.0 GB GPU RAM, 12.7 GB RAM sistem, dan ruang penyimpanan disk sebesar 112.6 GB.

2.5 Evaluasi

Untuk mengetahui tingkat keberhasilan model dalam mengklasifikasikan objek wisata religi, dilakukan proses evaluasi terhadap model yang telah dilatih. Evaluasi ini bertujuan untuk menilai performa model secara kuantitatif maupun kualitatif pada data uji yang belum pernah dilihat sebelumnya. Evaluasi model dilakukan untuk mengukur

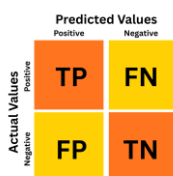
kinerja model dalam mengklasifikasikan objek wisata religi di Kota Semarang. Evaluasi mencakup tiga tahap utama, yaitu analisis kurva pelatihan-validasi, perhitungan metrik klasifikasi pada data uji, serta visualisasi *confusion matrix*. Selain itu, model juga disimpan dalam dua bentuk yaitu model penuh untuk pelatihan lanjutan dan *model inference* untuk kebutuhan *deployment*.

2.5.1 Kurva Pelatihan-Validasi

Selama proses pelatihan, nilai akurasi (accuracy) dan kerugian (loss) dicatat pada setiap epoch untuk data latih dan data validasi. Nilai-nilai ini kemudian divisualisasikan dalam bentuk grafik kurva untuk memantau kemajuan performa model secara visual. Analisis kurva ini sangat penting untuk mendeteksi potensi *overfitting* (kondisi di mana akurasi pelatihan terus meningkat sementara akurasi validasi stagnan atau menurun) maupun *underfitting* (kondisi di mana akurasi pelatihan dan validasi sama-sama rendah) [32]. Grafik kurva ini didokumentasikan sebagai bukti dari stabilitas proses pelatihan model.

2.5.2 Confusion Matrix

Confusion Matrix digunakan untuk menganalisis secara rinci performa sebuah model klasifikasi dengan membandingkan hasil prediksi dengan label aktualnya [33]. Bentuk *Confusion Matrix* dapat dilihat pada Gambar 3 berikut.



Gambar 3. Confusion Matrix

Pada Gambar 3 *Confusion Matrix* memberikan gambaran visual mengenai jenis-jenis kesalahan yang dibuat oleh model, sehingga evaluasi tidak hanya terbatas pada akurasi keseluruhan. Untuk masalah klasifikasi multi-kelas, *confusion matrix* berukuran $N \times N$, di mana N adalah jumlah kelas. Diagonal utama matriks menunjukkan jumlah prediksi yang benar, sedangkan sel-sel di luar diagonal menunjukkan kesalahan klasifikasi antar kelas. Dasar dari *confusion matrix* adalah empat komponen berikut:

- True Positive (TP): Jumlah data positif yang diprediksi dengan benar oleh model sebagai positif.
- True Negative (TN): Jumlah data negatif yang diprediksi dengan benar oleh model sebagai negatif.
- False Positive (FP): Dikenal juga sebagai *Type I Error*. Ini adalah jumlah data negatif yang salah diprediksi oleh model sebagai positif.
- False Negative (FN): Dikenal juga sebagai *Type II Error*. Ini adalah jumlah data positif yang salah diprediksi oleh model sebagai negatif.

2.5.3 Metrik Klasifikasi

Metrik klasifikasi mengevaluasi kinerja model dan memberi tahu seberapa baik atau buruk klasifikasi tersebut [32]. Dari komponen-komponen *confusion matrix*, prediksi model (y_{pred}) dibandingkan dengan label sebenarnya (y_{true}) untuk menghasilkan metrik kuantitatif utama menggunakan *classification report*. Metrik dihitung untuk setiap kelas k (ditandai dengan subskrip k).

$$Precision_k = \frac{TP_k}{TP_k + FP_k} \tag{1}$$

$$Recall_k = \frac{TP_k}{TP_k + FN_k} \tag{2}$$

$$F1_k = 2 \frac{Precision_k \cdot Recall_k}{Precision_k + Recall_k} \tag{3}$$

$$Accuracy = \frac{\sum_k TP_k}{N} \tag{4}$$

Presisi digunakan untuk mengukur tingkat ketepatan prediksi positif. Maksudnya yaitu dari semua data yang diprediksi sebagai kelas k , berapa persen yang benar-benar merupakan kelas k . Recall mengukur kemampuan model untuk mengidentifikasi semua sampel positif yang relevan, yaitu semua data yang seharusnya masuk dalam kelas k , berapa persen yang berhasil diprediksi dengan benar. F1-Score adalah rata-rata harmonik dari Presisi dan Recall, memberikan metrik tunggal yang menyeimbangkan keduanya. Akurasi mengukur proporsi total prediksi yang benar di semua kelas, dihitung dengan menjumlahkan semua prediksi yang benar (diagonal utama *confusion matrix*) dan membaginya dengan jumlah total data (N).

Selain metrik per kelas, nilai *macro average* (rata-rata metrik tanpa memperhitungkan jumlah sampel per kelas) dan *weighted average* (rata-rata metrik dengan bobot berdasarkan jumlah sampel per kelas) juga dilaporkan untuk

memberikan gambaran performa model secara menyeluruh. Dengan tahap evaluasi ini, kinerja model dapat dinilai secara menyeluruh, baik dari segi tren pembelajaran selama pelatihan, ketepatan klasifikasi pada data uji, maupun pola kesalahan antar kelas, sehingga dapat diketahui sejauh mana model telah mampu melakukan identifikasi objek wisata religi secara akurat dan konsisten [32]. Hasil evaluasi ini menjadi dasar untuk menilai sejauh mana model mampu mengenali objek wisata religi secara konsisten dan akurat, serta menjadi acuan dalam melakukan perbaikan atau pengembangan model pada penelitian selanjutnya.

3. HASIL DAN PEMBAHASAN

Setelah model dirancang menggunakan metodologi yang telah diuraikan pada bab sebelumnya, pada bab ini dibahas secara menyeluruh bukti kinerja dari model tersebut. Pembahasan akan diawali dengan melihat bagaimana hasil pengumpulan data, *preprocessing*, persiapan model untuk pelatihan, proses model belajar selama tahap pelatihan, kemudian dilanjutkan dengan pengujian performanya pada data-data yang sepenuhnya baru. Terakhir, semua hasil temuan ini akan didiskusikan secara mendalam untuk memahami makna, kontribusi, serta implikasinya.

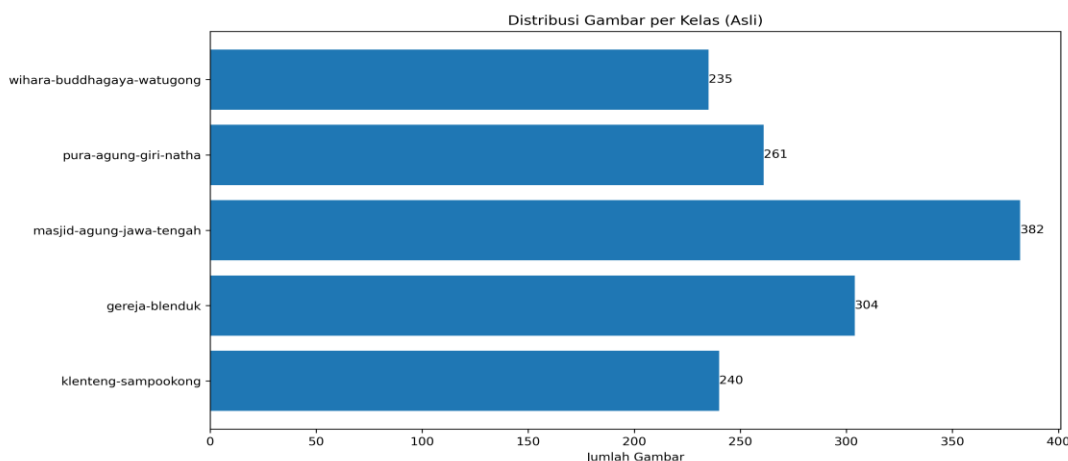
3.1 Hasil Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa gambar yang diperoleh melalui dua cara, yaitu dokumentasi langsung di lapangan dan pengunduhan gambar dari Google Images. Berikut ini contoh dataset gambar dari lima objek wisata religi di Kota Semarang disajikan dalam Gambar 4.



Gambar 4. Lima Objek Wisata Religi di Kota Semarang

Gambar yang dikumpulkan mencakup lima objek wisata religi di Kota Semarang, yaitu Wihara Buddhagaya Watugong, Masjid Agung Jawa Tengah, Pura Agung Giri Natha, Gereja Blenduk, dan Klenteng Sam Poo Kong seperti yang ditampilkan pada Gambar 4. Jumlah dataset gambar dari masing-masing objek wisata religi di Kota Semarang yang berhasil dikumpulkan disajikan pada Gambar 5.




Gambar 5. Distribusi Gambar per Kelas (Asli)

Gambar 5 merupakan distribusi gambar per kelas dari dataset gambar objek wisata religi di Kota Semarang. Dapat dilihat dari gambar 5 bahwa jumlah gambar tiap kelas tidak seimbang, jumlah gambar Wihara Buddhagaya Watugong adalah 235 gambar, Masjid Agung Jawa Tengah 382 gambar, Pura Agung Giri Natha 261 gambar, Gereja Blenduk 304 gambar, dan Klenteng Sam Poo Kong 240 gambar. Ketidakseimbangan ini dapat menyebabkan bias pada model. Membuat model lebih cenderung mengklasifikasikan gambar ke kelas dengan jumlah data lebih banyak.

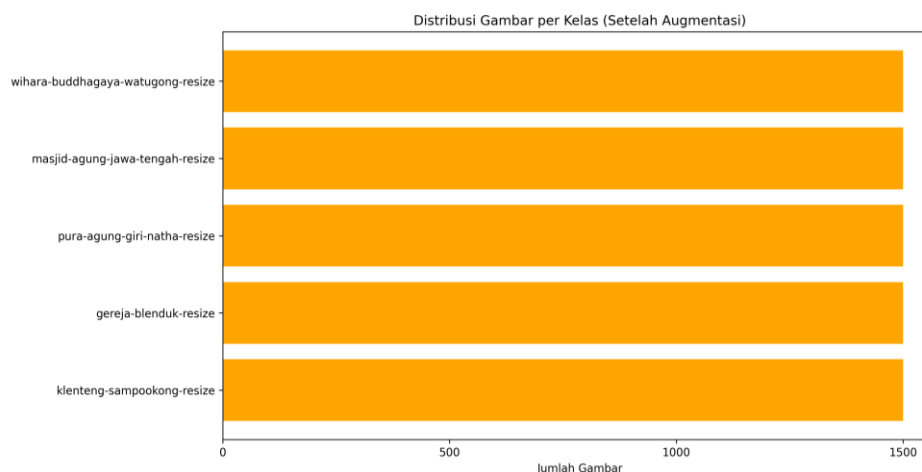
3.2 Hasil Preprocessing Data

Preprocessing data yang dilakukan pada penelitian ini adalah augmentasi gambar menggunakan teknik-teknik augmentasi yang ditunjukkan pada Gambar 6.



Gambar 6. Contoh Augmentasi Salah Satu Gambar

Untuk meningkatkan kemampuan generalisasi model, dataset pelatihan perlu memiliki variasi yang kaya. Augmentasi data adalah teknik yang diterapkan untuk memperbanyak gambar tanpa perlu mencari data baru. Seperti yang ditunjukkan pada Gambar 6, satu gambar asli diubah menjadi beberapa versi melalui serangkaian transformasi. Augmentasi yang dilakukan meliputi *horizontal flip*, *rotate*, *random brightness/contrast*, *ShiftScaleRotate*, *blur*, dan *resize*. Tujuan utamanya adalah untuk melatih model agar lebih tangguh dan mampu mengenali objek dalam berbagai kondisi visual, tidak hanya pada gambar yang kondisinya ideal. Tujuan penting lainnya dari augmentasi adalah untuk mengatasi masalah ketidakseimbangan kelas. Pada Gambar 7 berikut disajikan distribusi gambar per kelas setelah tahapan augmentasi.



Gambar 7. Distribusi Gambar per Kelas (Setelah Augmentasi)

Jika jumlah gambar antar kelas tidak sama, model dapat menjadi bias dan cenderung lebih baik dalam memprediksi kelas dengan data lebih banyak. Oleh karena itu, augmentasi digunakan untuk menambah jumlah gambar pada kelas-kelas yang lebih sedikit hingga semua kelas memiliki jumlah yang sama. Hasil dari proses ini, seperti terlihat pada Gambar 7, adalah dataset yang seimbang, di mana setiap dari lima kelas kini memiliki 1.500 gambar. Hal ini meningkatkan total dataset menjadi 7.500 gambar, yang merupakan fondasi yang kuat untuk melatih model yang akurat dan tidak memihak.

3.3 Persiapan Model untuk Training

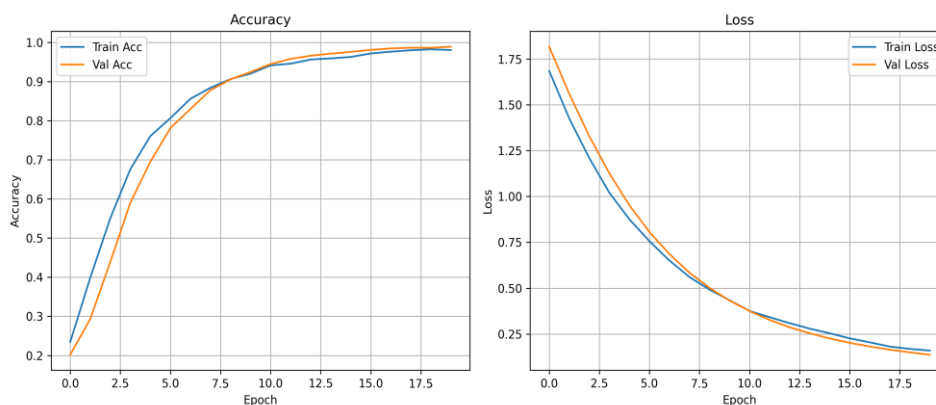
Persiapan model untuk pelatihan yaitu menggunakan pendekatan transfer learning dengan memanfaatkan arsitektur MobileNetV2. Model menggunakan bobot *pre-trained* dari dataset ImageNet, yang memungkinkannya mengenali fitur-fitur visual dasar. Konfigurasi model dirancang untuk menerima input gambar standar dengan dimensi 224 x 224 x 3 (RGB). Arsitektur model dibagi menjadi dua komponen utama. Komponen pertama adalah MobileNetV2 Base Model yang berfungsi murni sebagai *feature extractor*. Seluruh lapisan konvolusi pada base model dibekukan, yang berarti bobot-bobotnya tidak diperbarui selama proses pelatihan, untuk mempertahankan pengetahuan visual kompleks yang telah dipelajari dari dataset ImageNet. Komponen kedua adalah Kepala klasifikasi baru yang bersifat trainable, yakni satu-satunya bagian yang akan dilatih. Kepala klasifikasi ini terdiri dari lapisan GlobalAveragePooling2D (GAP), yang menerima feature map dari base model dan mereduksinya menjadi sebuah vektor fitur tunggal untuk mengurangi jumlah parameter dan membantu mencegah overfitting. Vektor fitur dari GAP kemudian diumpankan ke lapisan *output* Dense yang memiliki 5 unit neuron, sesuai dengan lima kelas objek wisata religi, dan menerapkan fungsi aktivasi softmax untuk menghasilkan keluaran berupa distribusi probabilitas. Hasil akhir dari arsitektur ini adalah sebuah model yang mampu memberikan prediksi probabilitas untuk kelima kelas target.

Proses pelatihan model menggunakan optimizer Adam untuk meminimalkan fungsi kerugian (*loss function*) *categorical crossentropy*, dengan *accuracy* yang dipantau sebagai metrik performa utama. Dengan pembagian dataset 70% data latih, 15% data validasi, dan 15% data uji. Pelatihan berlangsung selama 20 *epoch* dengan *batch size* sebesar 64. Dua *callback* digunakan, yaitu ModelCheckpoint untuk menyimpan versi model terbaik berdasarkan performa

validasi, dan ReduceLROnPlateau yang secara dinamis menyesuaikan laju pembelajaran dari $1e-6$ hingga minimum $1e-7$ ketika performa stagnan. Strategi gabungan ini sangat penting untuk menyempurnakan konvergensi model dan mencegah overfitting. Hasil penelitian dibagi menjadi dua tahap utama yaitu analisis proses pelatihan untuk memastikan model belajar dengan baik, dan evaluasi kuantitatif pada data uji untuk mengukur performa akhir model.

3.4 Hasil Training dan Evaluasi Model

Seluruh proses pelatihan model dievaluasi secara cermat dengan menjalankan pelatihan selama 20 epoch. Kemajuan dan performa model dipantau secara *real-time* melalui visualisasi kurva akurasi (*accuracy*) dan kerugian (*loss*), yang keduanya disajikan pada Gambar 8.



Gambar 8. Kurva Pelatihan-Validasi *Accuracy* dan *Loss*

Grafik pada Gambar 8 secara visual tersebut menunjukkan tren yang sangat ideal untuk sebuah proses pelatihan *deep learning*. Dapat diamati bahwa kurva akurasi untuk data latih (*training*) dan data validasi sama-sama menunjukkan kenaikan yang progresif dan konsisten dari epoch awal. Menjelang epoch akhir, kedua kurva tersebut kemudian tampak stabil, yang mengindikasikan bahwa model telah mencapai titik jenuh pembelajaran di tingkat akurasi yang sangat tinggi.

Sejalan dengan itu, fenomena yang berkebalikan namun sama-sama positif terlihat pada kurva kerugian (*loss*). Untuk kedua set data yaitu data latih dan data validasi, kurva juga menunjukkan penurunan yang stabil dan signifikan, yang akhirnya konvergen di nilai yang sangat rendah. Aspek yang paling penting dari grafik ini adalah celah (*gap*) yang minimal atau nyaris tidak ada antara kurva pelatihan dan validasi, baik pada metrik akurasi maupun *loss*. Kesenjangan yang tipis ini mengindikasikan bahwa model berhasil melakukan generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya dan tidak mengalami masalah umum berupa *overfitting*. Keberhasilan ini secara efektif memvalidasi efektivitas strategi pelatihan yang telah diterapkan, termasuk penggunaan augmentasi data dan pemilihan arsitektur.

Sebagai tahap evaluasi final, pengujian akhir dilakukan pada 1.125 gambar yang dialokasikan khusus sebagai *test set*. Langkah ini krusial untuk mengukur kinerja objektif model pada data yang sepenuhnya baru dan terpisah dari proses pelatihan. Hasil analisis kualitatif dari pengujian ini, yang secara visual disajikan dalam bentuk *Confusion Matrix*, dapat dilihat pada Gambar 9.



Gambar 9. Hasil Confusion Matrix

Hasil pengujian menunjukkan performa yang sangat memuaskan dengan akurasi keseluruhan mencapai 98%. Analisis kualitatif melalui *Confusion Matrix* pada Gambar 9 secara visual mengonfirmasi kinerja tinggi ini. Matriks menunjukkan adanya dominasi diagonal yang kuat, di mana sebagian besar prediksi jatuh pada sel yang benar (diagonal utama), dan hanya terdapat sedikit sekali kesalahan klasifikasi di sel *off-diagonal*. Hal ini menandakan model mampu membedakan kelima kelas objek wisata dengan sangat baik. Selain itu dilakukan analisis kuantitatif dengan metrik klasifikasi yang terpapar pada Tabel 1.

Tabel 1. Hasil Metrik Klasifikasi

Kelas	Precision	Recall	F1-Score	Support
Gereja Blenduk	0.97	0.99	0.98	225
Klenteng Sam Poo Kong	1.00	0.99	0.99	225
Masjid Agung Jawa Tengah	0.98	0.96	0.97	225
Pura Agung Giri Natha	1.00	1.00	1.00	225
Wihara Buddhagaya Watugong	0.97	0.99	0.98	225
Accuracy			0.98	1125
Macro Avg	0.98	0.98	0.98	1125
Weighted Avg	0.98	0.98	0.98	1125



Secara kuantitatif, Tabel 1 merinci metrik kinerja untuk setiap kelas. Kinerja luar biasa ditunjukkan pada kelas Pura Agung Giri Natha yang mencapai nilai sempurna (1.00) untuk semua metrik. Kelas lain seperti Gereja Blenduk, Klenteng Sam Poo Kong, dan Wihara Buddhagaya Watugong juga mencatatkan F1-Score yang sangat tinggi, yaitu 0.98 dan 0.99, yang menunjukkan keseimbangan yang sangat baik antara *precision* dan *recall*. Sedikit penurunan performa pada kelas Masjid Agung Jawa Tengah dengan *recall* 0.96, yang mengindikasikan model sesekali keliru mengenali gambar masjid sebagai objek lain. Namun, secara keseluruhan, nilai rata-rata (*macro* dan *weighted average*) sebesar 0.98 menegaskan bahwa model memiliki performa yang konsisten dan seimbang di semua kelas.





3.5 Pengujian

Setelah model dievaluasi menggunakan metrik-metrik standar, tahap selanjutnya adalah melakukan pengujian untuk mensimulasikan penggunaan model di dunia nyata. Pengujian ini bertujuan untuk memvalidasi kemampuan model dalam mengidentifikasi gambar-gambar individual yang belum pernah dilihat sebelumnya, termasuk gambar yang tidak termasuk dalam salah satu dari lima kelas yang telah ditentukan. Untuk meningkatkan keandalan dan pengalaman pengguna pada aplikasi di masa depan, sebuah ambang batas keyakinan (*confidence threshold*) ditetapkan pada 80% (0.8). Artinya, sebuah prediksi hanya akan diterima dan ditampilkan jika skor keyakinan dari model berada di atas 80%. Jika skor tertinggi berada di bawah ambang batas ini, sistem akan menganggap gambar tersebut "tidak dikenali". Pendekatan ini terbukti efektif untuk menyaring hasil prediksi yang paling relevan, meningkatkan akurasi, dan mengurangi "noise" atau kesalahan klasifikasi pada gambar-gambar yang ambigu atau tidak sesuai.

Pengujian dilakukan dengan memberikan enam gambar baru kepada model yaitu satu gambar representatif untuk masing-masing dari kelima kelas objek wisata, dan satu gambar acak yang berada di luar lingkup kelas (gambar makam). Hasil dari pengujian ini dirangkum dalam Tabel 2.

Tabel 2. Hasil Pengujian Model dengan Gambar Individual

No.	Gambar Uji	Hasil Prediksi	Skor Keyakinan (Confidence)	Keterangan
1.		Gereja Blenduk	91.28%	Berhasil
2.		Klenteng Sam Poo Kong	90.17%	Berhasil

3.	 <p>Prediksi: Masjid Agung Jawa Tengah (81.30%)</p>	Masjid Agung Jawa Tengah	81.30%	Berhasil
4.	 <p>Prediksi: Pura Agung Giri Natha (98.88%)</p>	Pura Agung Giri Natha	98.88%	Berhasil
5.	 <p>Prediksi: Wihara Buddhagaya Watugong (92.11%)</p>	Wihara Buddhagaya Watugong	92.11%	Berhasil
6.	 <p>Gambar tidak dikenali, coba foto lagi</p>	Gambar Tidak Dikenali	< 80% (di bawah ambang batas)	Berhasil (Ditolak)

Hasil pengujian individual pada gambar-gambar baru secara efektif memvalidasi kinerja model yang sangat baik dan sesuai harapan. Model berhasil mengidentifikasi kelima kelas objek wisata religi dengan benar, di mana semua prediksi menghasilkan skor keyakinan di atas ambang batas 80%. Tingkat keyakinan tertinggi dicapai pada gambar Pura Agung Giri Natha (98.88%), yang mengindikasikan fitur arsitekturnya sangat distingtif, sementara skor terendah diperoleh Masjid Agung Jawa Tengah (81.30%), hasil yang konsisten dengan temuan pada *confusion matrix* yang menunjukkan adanya sedikit kebingungan pada kelas tersebut. Lebih dari itu, aspek krusial dari pengujian ini adalah keberhasilan model dalam menolak gambar di luar kelas (gambar makam) dengan memberikan *output* "Gambar tidak dikenali". Keberhasilan penolakan ini, yang dimungkinkan oleh penerapan ambang batas keyakinan, membuktikan bahwa model tidak memaksakan prediksi yang salah. Secara keseluruhan, hasil pengujian ini menunjukkan bahwa model yang dibuat tidak hanya memiliki ketepatan secara statistik, tetapi juga menunjukkan ketahanan dan kemudahan untuk diterapkan dalam kehidupan nyata, karena dapat membedakan antara data yang penting dan yang tidak penting.

3.6 Pembahasan

Keberhasilan implementasi model MobileNetV2 dalam penelitian ini terbukti melalui pencapaian akurasi sangat tinggi sebesar 98% dalam mengidentifikasi kelima ikon wisata religi Semarang, yang sekaligus menandakan bahwa tujuan utama penelitian telah tercapai. Kinerja ini tidak hanya memvalidasi efektivitas metode *transfer learning* dan arsitektur MobileNetV2, tetapi juga menunjukkan model yang mampu menolak gambar di luar kelas berkat penerapan ambang batas keyakinan. Jika dibandingkan dengan penelitian sebelumnya, performa model ini terbukti sebanding dengan studi serupa yang menggunakan MobileNetV2 oleh Saputra, dkk., di tahun 2022 sebesar 98,64% [8] dan bahkan lebih unggul dari arsitektur yang lebih berat seperti ResNet-50 pada konteks objek wisata regional oleh Mira, dkk., di tahun 2022 sebesar 88,52% [6]. Kontribusi utama dari penelitian ini adalah kebaruannya, yaitu penelitian sebelumnya hanya fokus pada satu jenis objek budaya, penelitian ini menjadi yang pertama dalam menerapkan metode deep learning pada kumpulan data unik yang mewakili keberagaman agama di Kota Semarang dengan lima jenis objek. Meskipun demikian, perlu diakui bahwa penelitian ini memiliki dua keterbatasan utama. Pertama, dataset yang digunakan belum mencakup gambar-gambar dalam kondisi dunia nyata yang lebih beragam kondisi pengambilan gambarnya, seperti pada malam hari atau sudut pandang yang tidak biasa. Kedua, lingkup model saat ini hanya sebagai pengklasifikasi yang mengenali keseluruhan isi gambar, bukan sebagai pendeteksi objek yang mampu menemukan sebuah bangunan di dalam foto yang ramai. Oleh karena itu, pengembangan di masa depan sangat disarankan untuk fokus pada pengayaan data dan evolusi model ke arah deteksi objek.

4. KESIMPULAN

Penelitian ini berhasil menjawab tantangan kurangnya promosi digital bagi lima ikon wisata religi di Kota Semarang. Dengan membangun model klasifikasi citra menggunakan arsitektur MobileNetV2 dan metode *transfer learning*, penelitian ini sukses menghasilkan sebuah sistem yang mampu mengidentifikasi kelima lokasi tersebut dengan akurasi sangat tinggi, yaitu 98%. Hasil ini secara efektif membuktikan bahwa pendekatan yang dipilih mampu menjadi solusi konkret untuk masalah yang telah diidentifikasi. Kesimpulan utamanya adalah bahwa arsitektur MobileNetV2 dengan *transfer learning* terbukti sangat efektif dan efisien untuk kasus identifikasi objek wisata religi Semarang. Keberhasilan ini tidak hanya diukur dari akurasi statistik yang tinggi, tetapi juga dari kemampuan praktis model untuk menolak gambar yang tidak relevan, yang menunjukkan keandalannya untuk aplikasi di dunia nyata. Dengan demikian, penelitian ini berhasil mengisi celah penelitian, yakni dengan menjadi studi pertama yang secara spesifik mengembangkan model klasifikasi gambar objek wisata religi yang merepresentasikan harmoni multi-agama di kota Semarang. Meskipun berhasil, penelitian ini memiliki keterbatasan yang membuka peluang untuk pengembangan selanjutnya. Kinerja model saat ini terbatas pada dataset dengan kondisi gambar yang relatif ideal dan fungsinya hanya sebagai pengklasifikasi. Oleh karena itu, penelitian di masa depan sangat disarankan untuk berfokus pada dua hal yaitu pertama, meningkatkan ketangguhan model dengan melatihnya pada dataset yang lebih beragam, dan kedua, pengembangan ke penerapan sistem yang mampu mendeteksi objek pada sektor promosi pariwisata.

REFERENCES

- [1] A. Mardian, M. Mandaka, dan A. D. Susanti, "Design of Multi Religious Tourism Area with Approach Neo Vernacular Architecture in Semarang City," *Arsitektur Universitas Pandanaran Jurnal*, vol. 3, no. 2, hlm. 83–104, Nov 2023, doi: 10.54325/arsip.v3i2.80.
- [2] Armiah, R. Khaliq, A. Sagir, R. Yani Gusriani, dan A. H. Gazali, "Escalating the spiritual experience of guru sekumpul tomb's religious tourism through marketing communication strategy.," *Khazanah: Jurnal Studi Islam dan Humaniora*, vol. 21, no. 2, hlm. 225–244, Des 2023, doi: 10.18592/khazanah.v20i1.10794.
- [3] E. E. Nuryanto, "MTC Jateng : Promosi Wisata Religi Harus Diubah, Jangan Hanya Getok Tular," *suaramerdeka.com*, Semarang, hlm. 1–2, 10 Januari 2023. Diakses: 31 Oktober 2025. [Daring]. Tersedia pada: <https://www.suaramerdeka.com/jawa-tengah/pr-046512914/mtc-jateng-promosi-wisata-religi-harus-diubah-jangan-hanya-getok-tular>
- [4] Latifah, "Imaji Borobudur sebagai Destinasi Pusat Religi Dunia melalui Media Digital," *Bandung Conference Series: Journalism*, vol. 3, no. 3, hlm. 304–310, Okt 2023, doi: 10.29313/bcsj.v3i3.9640.
- [5] S. P. Adithama, B. Yudi Dwiandiyanta, dan S. B. Wiadji, "Identification of Batik in Central Java using the Transfer Learning Method 77," *Jurnal Buana Informatika*, vol. 14, no. 2, hlm. 77–86, Nov 2023, doi: 10.24002/jbi.v14i02.6977.
- [6] M. Mira, I. Sembiring, dan H. D. Purnomo, "Implementasi Transfer Learning Pada Algoritma Convolutional Neural Network untuk Mengklasifikasikan Image Objek Wisata," *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 1, Jun 2022, doi: 10.47065/bits.v4i1.1764.
- [7] J. Jha dan S. Singh Bhaduarua, "Fast retrieval and efficient identification of monument images using features based adaptive clustering and optimized deep belief network," *The Imaging Science Journal*, vol. 71, no. 6, hlm. 499–517, Agu 2023, doi: 10.1080/13682199.2023.2183624.
- [8] O. Saputra, D. Iskandar Mulyana, dan M. B. Yel, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Senjata Tradisional Di Jawa Tengah Dengan Metode Transfer Learning," *Jurnal Sistem Komputer dan Kecerdasan Buatan*, vol. 5, no. 2, hlm. 45–52, Mar 2022, doi: 10.47970/siskom-kb.v5i2.282.
- [9] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustainability (Switzerland)*, vol. 15, no. 3, Feb 2023, doi: 10.3390/su15031906.
- [10] A. Kazi, S. Shikalpure, dan V. Injamuri, "Multiclass Classification using Enhanced MobileNet V2 Architecture," *International Journal of Scientific Research in Engineering and Management*, 2024, doi: 10.55041/IJSREM35845.
- [11] G. Singh, K. Guleria, dan S. Sharma, "A Fine-Tuned MobileNetV2 Deep Learning Model for Citrus Fruit Disease Classification," dalam *2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS)*, IEEE, Nov 2024, hlm. 418–423. doi: 10.1109/ICTACS62700.2024.10841273.
- [12] H. Wang, Q. Qi, W. Sun, X. Li, B. Dong, dan C. Yao, "Classification of skin lesions with generative adversarial networks and improved MobileNetV2," *Int J Imaging Syst Technol*, vol. 33, no. 5, hlm. 1561–1576, Sep 2023, doi: 10.1002/ima.22880.
- [13] R. Jain, R. Sharma, D. Tiwari, K. Joshi, dan V. Jain, "Enhanced Classification of Intel Images Using Refined EfficientNet and MobileNetV2 Frameworks," dalam *2023 4th International Conference on Intelligent Technologies (CONIT)*, IEEE, Jun 2024, hlm. 1–4. doi: 10.1109/CONIT61985.2024.10627673.
- [14] T. Hasuiki, Y. Liang, H. Katagiri, dan H. Tsuda, "Proposal of a Tourist Attractions' Introduction Creating Tool Using Deep Learning," dalam *2024 16th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, IEEE, Jul 2024, hlm. 556–561. doi: 10.1109/IIAI-AAI63651.2024.00106.
- [15] N. Cho, Y. Kang, J. Yoon, S. Park, dan J. Kim, "Classifying Tourists' Photos and Exploring Tourism Destination Image Using a Deep Learning Model," *Journal of Quality Assurance in Hospitality & Tourism*, vol. 23, no. 6, hlm. 1480–1508, Nov 2022, doi: 10.1080/1528008X.2021.1995567.
- [16] F. Zhang dan J. Li, "Tourism Image Recognition and Scenic Spot Recommendation System Based on Deep Learning," dalam *2024 3rd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDAI)*, IEEE, Okt 2024, hlm. 409–415. doi: 10.1109/ICDAI65086.2024.00081.
- [17] Q. Zhang, Y. Liu, L. Liu, S. Lu, Y. Feng, dan X. Yu, "Location identification and personalized recommendation of tourist attractions based on image processing," *Traitement du Signal*, vol. 38, no. 1, hlm. 197–205, Feb 2021, doi: 10.18280/TS.380121.



- [18] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, dan F. Shen, “Image Data Augmentation for Deep Learning: A Survey,” Apr 2022, doi: <https://doi.org/10.48550/arXiv.2204.08610>.
- [19] N. Cauli dan D. Reforgiato Recupero, “Survey on Videos Data Augmentation for Deep Learning Models,” 1 Maret 2022, *MDPI*. doi: 10.3390/ai14030093.
- [20] L. M. Haji, O. M. Mustafa, S. A. Abdullah, dan O. M. Ahmed, “Enhanced Convolutional Neural Network for Fashion Classification,” *Engineering, Technology and Applied Science Research*, vol. 14, no. 5, hlm. 16534–16538, Okt 2024, doi: 10.48084/etasr.8147.
- [21] J. Hou, Z. Zhang, dan Z. Lin, “Exploring Integration methods for Image Data Augmentation,” *International Conference on Internet of Things, Automation and Artificial Intelligence (IoTAI)*, hlm. 707–703, Okt 2024, doi: 10.13140/RG.2.2.30698.12485.
- [22] S. Abusalim, S. A. Mostafa, N. Zakaria, S. J. Abdulkadir, dan N. Mokhtar, “Data Augmentation on Intra-Oral Images Using Image Manipulation Techniques,” dalam *2022 International Conference on Digital Transformation and Intelligence, ICDI 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022, hlm. 117–120. doi: 10.1109/ICDI57181.2022.10007158.
- [23] Z. Gao, Y. Tian, S.-C. Lin, dan J. Lin, “A CT Image Classification Network Framework for Lung Tumors Based on Pre-trained MobileNetV2 Model and Transfer learning, And Its Application and Market Analysis in the Medical field,” *Proceedings of the 5th International Conference on Signal Processing and Machine Learning*, hlm. 89–95, Jan 2025, doi: <https://doi.org/10.54254/2755-2721/2025.20605>.
- [24] T. Barman dan S. Susan, “Multi-Label Remote Sensing Image Classification using MobileNetV2,” dalam *2024 15th International Conference on Computing Communication and Networking Technologies, ICCCNT 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICCCNT61001.2024.10725506.
- [25] M. Belmir, W. Difallah, dan A. Ghazli, “A Reliable Apple Leaf Disease Identification Using a Deep Learning-Based MobileNetV2 to Safeguard Apple Fruit Safety,” dalam *2024 4th International Conference on Embedded & Distributed Systems (EDiS)*, IEEE, Nov 2024, hlm. 279–284. doi: 10.1109/EDiS63605.2024.10783370.
- [26] F. Ramadhani, S. Rahardianto, dan M. Masjkur, “Acne Severity Classification Study Using Convolutional Neural Network Algorithm with MobileNetV2 Architecture,” *Indonesian Journal of Statistics and Its Applications*, vol. 8, no. 2, hlm. 112–128, Des 2024, doi: 10.29244/ijsa.v8i2p112-128.
- [27] H. Bichri, A. Chergui, dan M. Hain, “Investigating the Impact of Train / Test Split Ratio on the Performance of Pre-Trained Models with Custom Datasets,” *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 2, 2024, doi: 10.14569/IJACSA.2024.0150235.
- [28] R. Altabeiri, M. Alsafasfeh, dan M. Alhasanat, “Image compression approach for improving deep learning applications,” *International Journal of Electrical and Computer Engineering*, vol. 13, no. 5, hlm. 5607–5616, Okt 2023, doi: 10.11591/ijece.v13i5.pp5607-5616.
- [29] L. Trihardianingsih, A. Sunyoto, dan T. Hidayat, “Classification of Tea Leaf Diseases Based on ResNet-50 and Inception V3,” *Sinkron*, vol. 8, no. 3, hlm. 1564–1573, Jul 2023, doi: 10.33395/sinkron.v8i3.12604.
- [30] R. Prabowo, A. Roudhoh, dan F. Matematika dan Ilmu Pengetahuan Alam, “Klasifikasi Image Tumbuhan Obat Sirih dan Binahong Menggunakan Metode Convolutional Neural Network (CNN),” *Jurnal Komputasi*, vol. 10, no. 2, hlm. 48–54, Okt 2022, doi: 10.23960/komputasi.v10i2.3178.
- [31] F. Masykur, M. B. Setyawan, dan K. Winangun, “Optimalisasi Epoch Pada Klasifikasi Citra Daun Tanaman Padi Menggunakan Convolutional Neural Network (CNN) MobileNet Epoch Optimization on Rice Leaf Image Classification Using Convolutional Neural Network (CNN) MobileNet,” *Journal of Computing Engineering, System and Science*, vol. 7, no. 2, hlm. 581–590, Jul 2022, doi: 10.24114/cess.v7i2.37336.
- [32] S. Riyanarto, S. Shoffi Izza, Malikhah, P. Doni Putra, dan A. M. Syauqi Hanif, *Machine Learning Deep Learning Konsep dan Pemrograman Python*, 1 ed. Yogyakarta: Penerbit ANDI, 2023. Diakses: 31 Oktober 2025. [Daring]. Tersedia pada: <https://books.google.co.id/books?id=byWFEAAAQBAJ&lpg=PP1&hl=id&pg=PP1#v=onepage&q&f=false>
- [33] P. Rifkie, *Algoritma Machine Learning*, 1 ed. Bandung: Informatika Bandung, 2021. Diakses: 31 Oktober 2025. [Daring]. Tersedia pada: <https://repositori.telkomuniversity.ac.id/pustaka/226871/algoritma-machine-learning.html>