

Implementasi Metode CNN Berbasis Transfer Learning dengan Arsitektur MobileNetV2 dalam Klasifikasi dan Pemetaan Tempat Wisata

¹Mira*, ²Christian Cahyaningtyas, ³Maya Sari, ⁴Yuliana

^{1,2,3,4}Teknologi Informasi, Institut Shanti Bhuana

^{1,2,3,4} Jl Bukit Karmel No.1 Bengkayang, Kalimantan Barat, Indonesia

E-mail: mira@shantibhuana.ac.id, ²christi@shantibhuana.ac.id, ³maya@shantibhuana.ac.id,

⁴yuliana@shantibhuana.ac.id

*Corresponding Author

Abstrak— Pertumbuhan pariwisata di era digital mendorong pemanfaatan media sosial sebagai sumber data visual untuk analisis destinasi. Penelitian ini bertujuan mengklasifikasikan dan memetakan objek wisata di Kalimantan Barat menggunakan metode Convolutional Neural Network (CNN) berbasis transfer learning dengan arsitektur MobileNetV2. Sebanyak 454 citra dikumpulkan melalui web scraping dari akun Instagram @enjoykalbar, kemudian melalui proses eliminasi, augmentasi, normalisasi, dan pelabelan manual berdasarkan kategori wisata Disporapar Kalimantan Barat, yaitu Bukit, Pantai, Riam, Budaya, Danau, Sungai, Gua, dan Hutan. Dataset dibagi menjadi data latih (70%), validasi (20%), dan uji (10%). Model dibangun dengan membekukan lapisan awal MobileNetV2 dan menambahkan classification head, lalu dilatih selama 20 epoch menggunakan Adam Optimizer dan callback EarlyStopping serta ReduceLROnPlateau. Hasil pelatihan menunjukkan akurasi latih 95,8%, validasi 88,1%, dan uji 80%. Evaluasi lebih lanjut menggunakan classification report menghasilkan akurasi keseluruhan 89%, dengan precision rata-rata 0,93, recall 0,86, dan F1-score 0,88. Model kemudian diintegrasikan dalam sistem pemetaan interaktif berbasis kategori dan koordinat untuk menampilkan persebaran objek wisata di 12 kabupaten dan 2 kota. Hasil menunjukkan pendekatan CNN transfer learning efektif untuk klasifikasi citra wisata dan mendukung visualisasi spasial dalam promosi serta perencanaan pariwisata.

Kata Kunci — CNN; Transfer learning; MobileNetV2; Klasifikasi Citra; Pemetaan SIG; Tempat Wisata.

Abstract— The growth of tourism in the digital era encourages the use of social media as a source of visual data for destination analysis. This study aims to classify and map tourist attractions in West Kalimantan using a transfer learning-based Convolutional Neural Network (CNN) method with the MobileNetV2 architecture. A total of 454 images were collected through web scraping from the Instagram account @enjoykalbar, then through a process of elimination, augmentation, normalization, and manual labeling based on the West Kalimantan Disporapar tourism categories, namely Hills, Beaches, Cascades, Culture, Lakes, Rivers, Caves, and Forests. The dataset was divided into training data (70%), validation (20%), and test (10%). The model was built by freezing the initial layers of MobileNetV2 and adding a classification head, then drilled for 20 epochs using the Adam Optimizer and EarlyStopping and ReduceLROnPlateau callbacks. The training results showed a training accuracy of 95.8%, validation accuracy of 88.1%, and test accuracy of 80%. Further evaluation using the classification report yielded an overall accuracy of 89%, with an average precision of 0.93, a recall of 0.86, and an F1-score of 0.88. The model was then integrated into a category- and coordinate-based interactive mapping system to display the distribution of tourist attractions across 12 districts and 2 cities. The results demonstrate that the CNN transfer learning approach is effective for tourism image classification and supports spatial visualization in tourism promotion and planning.

Keywords — CNN; Transfer learning; MobileNetV2; Image Classification; GIS Mapping; Tourist Attractions.

I. PENDAHULUAN

Industri pariwisata mengalami pertumbuhan yang pesat, seiring dengan meningkatnya akses informasi di era digital. Salah satu platform yang berperan penting dalam penyebaran informasi wisata adalah media sosial, khususnya Instagram. Platform ini memungkinkan pengguna untuk membagikan pengalaman dan momen perjalanan mereka dalam bentuk foto, dan video yang sering dilengkapi dengan lokasi. Unggahan tersebut tidak hanya menjadi dokumentasi pribadi, tetapi juga dapat memberikan gambaran mengenai daya tarik suatu destinasi, tren wisata, serta preferensi wisatawan [1][2]. Dengan semakin banyaknya unggahan yang berkaitan dengan wisata, analisis citra dari media sosial menjadi tantangan sekaligus peluang dalam memahami daya tarik wisata secara lebih mendalam.

Data visual dari media sosial berpotensi besar untuk dianalisis, tetapi memerlukan pendekatan teknis yang canggih agar dapat menghasilkan informasi yang relevan dan akurat. Beberapa tahun terakhir, kemajuan dalam kecerdasan buatan (*Artificial Intelligence/AI*) dan pembelajaran mesin (*Machine Learning*) telah memungkinkan pengolahan data citra secara otomatis. Salah satu pendekatan yang banyak digunakan adalah jaringan saraf tiruan (*Artificial Neural Network/ANN*), khususnya Convolutional Neural Network (CNN), yang dirancang untuk mengekstraksi pola visual dari gambar [3][4]. CNN telah terbukti efektif dalam berbagai tugas klasifikasi citra, termasuk untuk mengidentifikasi kategori pemandangan seperti gunung, hutan, laut, dan lainnya [5]. Data citra dikumpulkan dari media sosial Instagram menggunakan teknik web crawling berbasis Python. Proses ini dilakukan secara otomatis dengan memilih salah satu akun yang mempunyai konten objek wisata yakni @enjoykalbar. Akun ini, hingga saat ini masih aktif, serta konsisten memfokuskan konten pada objek yang ada di Kalimantan Barat, yang dapat dilihat dari dominasi unggahan yang menampilkan destinasi wisata alam seperti pantai, riam, dan bukit serta menampilkan objek wisata di berbagai kabupaten/kota di Kalimantan Barat, Sehingga representatif sebagai objek penelitian. Proses crawling menggunakan IDE Visual Studio Code, Google Colaboratory dan pustaka yang mendukung proses analisis data.

Proses Crawling dapat mengumpulkan puluhan hingga ratusan gambar berdasarkan tujuan penelitian yakni postingan feed yang ada di akun @enjoykalbar [6]. Setelah data citra dikumpulkan, kemudian dilanjutkan dengan tahap preprocessing untuk menghasilkan format data yang seragam, guna meningkatkan kualitas data sebelum digunakan dalam pelatihan model klasifikasi [7]. Data citra kemudian dikategorikan ke dalam kelas, yang merujuk pada destinasi wisata kalbar oleh Disporapar kalbar yakni alam (bukit, riam, air terjun, pantai, dan danau), budaya, sejarah dan kuliner (disporapar.kalbarprov.go.id). Pemanfaatan citra dari media sosial untuk klasifikasi objek wisata memiliki keunggulan dari sisi efisiensi dan jangkauan data. Metode ini lebih cepat dan hemat biaya, dibandingkan survei lapangan, serta mampu memberikan gambaran yang luas mengenai destinasi wisata yang sedang populer [8]. Proses klasifikasi menggunakan metode deep learning berbasis CNN yang dikombinasikan dengan pendekatan transfer learning. Transfer learning memungkinkan penggunaan model yang telah dilatih sebelumnya, seperti pada dataset ImageNet, kemudian disesuaikan (fine-tuned) dengan dataset baru. Dalam hal ini adalah citra objek wisata dari Instagram [9]. Arsitektur CNN yang digunakan dalam penelitian ini adalah MobileNetV2, yang dikenal sebagai model ringan dan efisien. MobileNetV2 menggunakan teknik *depthwise separable convolution* dan *inverted residual blocks* untuk mengurangi jumlah parameter tanpa mengorbankan akurasi [9]. Hal ini menjadikan MobileNetV2 sangat sesuai untuk klasifikasi citra wisata berbasis media sosial yang beragam dalam kualitas dan ukuran file.

Implementasi pelatihan menggunakan lapisan awal model MobileNetV2 dibekukan (*frozen*), dan hanya lapisan akhir (*classification head*) yang dilatih ulang menggunakan dataset lokal yang telah dilabeli. Strategi ini membuat proses pelatihan lebih cepat dan tetap efektif meskipun dengan data terbatas. Terdapat tantangan dalam hal variasi sudut pengambilan gambar, kualitas gambar yang tidak seragam, dan kemungkinan keberadaan objek yang tidak relevan dapat memengaruhi hasil klasifikasi [10]. Oleh karena itu, diperlukan proses preprocessing yang cermat dan seleksi data yang tepat untuk mencapai hasil klasifikasi yang optimal [11]. Sejumlah penelitian terdahulu mendukung penggunaan CNN dalam klasifikasi citra. Misalnya, pengklasifikasian pemandangan alam seperti gunung, laut, dan hutan telah menunjukkan akurasi yang tinggi [12]. Studi lain di Jawa Timur memanfaatkan crawling dan pengolahan citra media sosial untuk mengekstrak informasi destinasi wisata, meskipun keberhasilannya bergantung pada kualitas data [13]. CNN juga berhasil diterapkan dalam klasifikasi data radar, dengan akurasi pelatihan mencapai 96,2% dan validasi sebesar 96,6% [14].

Penerapan MobileNetV2 dengan transfer learning dalam konteks pariwisata masih jarang dibahas secara khusus. Sebagian besar penelitian sebelumnya berfokus pada bidang lain seperti kesehatan, pertanian, dan retail. Contohnya, Davies dan Jacob menerapkan MobileNetV2 dalam deteksi kanker payudara berbasis citra termografi, dan memperoleh akurasi hingga 98,69% [15]. Patel dan Shah mengembangkan diagnosis COVID-19 dari X-ray dada dengan akurasi 96%, serta mengatasi tantangan seperti ketidakseimbangan data [16]. Dou dkk mengintegrasikan modul perhatian CBAM ke dalam MobileNetV2 untuk klasifikasi penyakit citrus dan mencapai akurasi 98,75% [17]. Gondhalekar

dan Gulzar juga menunjukkan performa tinggi MobileNetV2 pada klasifikasi gambar hewan dan buah [18][19].

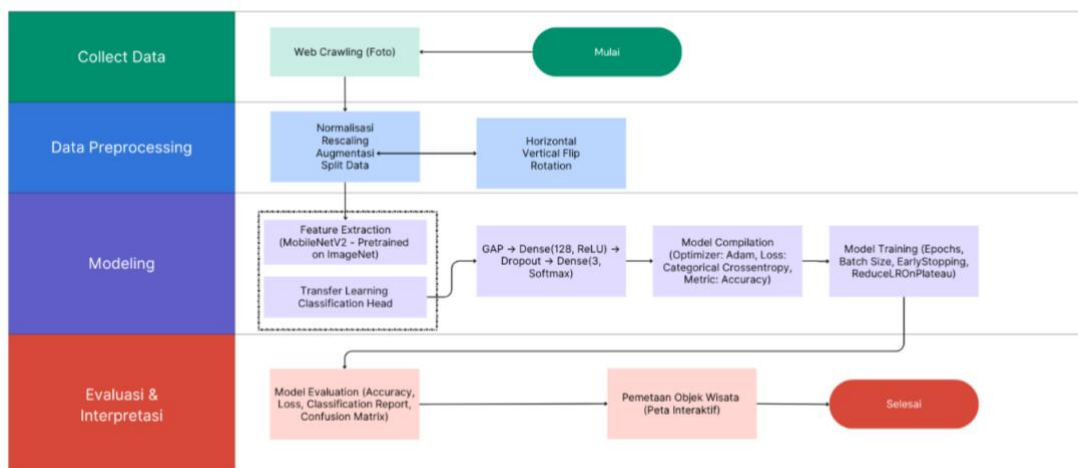
Berbeda dari studi-studi tersebut, penelitian ini menghadirkan pendekatan kontekstual dalam bidang pariwisata digital. Penelitian tidak hanya mengimplementasikan klasifikasi citra berbasis CNN dan MobileNetV2, tetapi juga mengintegrasikan hasil klasifikasi ke dalam sistem pemetaan spasial. Lokasi unggahan gambar digunakan untuk memetakan persebaran objek wisata secara geografis, yang divisualisasikan dalam bentuk peta interaktif. Integrasi klasifikasi citra dan pemetaan lokasi ini diharapkan menjadi dasar pengembangan sistem informasi geografis (SIG) berbasis media sosial. Sistem ini berpotensi digunakan dalam strategi promosi wisata, perencanaan destinasi, hingga sistem rekomendasi berbasis lokasi. Penelitian ini membangun sistem klasifikasi dan pemetaan objek wisata di Kalimantan Barat dengan memanfaatkan data citra dari Instagram. Metode yang digunakan adalah Convolutional Neural Network (CNN) berbasis transfer learning dengan arsitektur MobileNetV2, yang diharapkan mampu mengklasifikasikan citra secara akurat dan efisien serta mendukung pemetaan geografis dalam sistem informasi berbasis media sosial.

II. METODE PENELITIAN


Penelitian ini menerapkan metode Convolutional Neural Network (CNN) berbasis transfer learning dengan arsitektur MobileNetV2 untuk klasifikasi citra objek wisata. Implementasi dilakukan secara praktis menggunakan bahasa python, dengan bantuan library Tensorflow dan Keras. Transfer learning dikembangkan untuk tugas tertentu dengan konsep pembelajaran mesin berdasarkan pola [20], sedangkan MobileNetV2 bekerja dengan konsep struktur residual terbalik dan kombinasi tingkatan bottleneck residual [21], [22] Adapun desain penelitian yang dilakukan dalam penelitian dijelaskan dengan diagram alir pada Gambar 1.

Pengumpulan Data

Proses pengumpulan data menggunakan Metode Web Crawling yakni instagram scraping. Sumber data diambil dari akun instagram @enjoykalbar, yang merupakan salah satu akun dengan konsen konten objek wisata meskipun belum memuat seluruh objek wisata yang ada di Kalbar. Proses pengumpulan data, penulis juga melakukan penyaringan data dengan memilih postingan berupa foto dengan kualitas gambar yang baik serta menghapus duplikat data, video dan postingan yang bukan merupakan objek wisata. Jumlah data yang berhasil dikumpulkan sebanyak 454 data image objek wisata dari akun instagram @enjoykalbar. Data image objek wisata diberi label secara manual dengan modul pada *visual basic for Applications* (VBA) dengan kategori yakni, bukit, pantai, riam, budaya, danau, sungai, Gua, dan Hutan . Proses labeling ini disesuaikan dengan destinasi wisata kalbar oleh Disporapar kalbar. Selain labeling objek wisata, selanjutnya ditentukan lokasi wisata yakni kabupaten dan nama tempat wisata guna menentukan titik koordinat lokasi untuk proses pemetaan dalam peta klasifikasi objek wisata.



Gambar 1. Diagram Alur Penelitian



Gambar 2. Arsitektur MobileNetV2

Preprocessing Data

Tahapan preprocessing data melibatkan eliminasi data, proses normalisasi, rescaling, augmentasi dan pemisahan dataset. Eliminasi data dilakukan untuk meningkatkan kualitas data dengan menghapus data yang tidak sesuai dengan tujuan penelitian, yakni objek wisata. Sehingga dalam penelitian ini beberapa data dihapus seperti poster wisata, promosi objek wisata dan beberapa data image yang bukan objek wisata. Normalisasi dengan mengubah ukuran citra ke dimensi 224x224 piksel agar sesuai dengan input model CNN. Rescaling piksel gambar dinormalisasi dalam rentang [0,1] dengan $\text{rescale} = 1./255$ untuk meningkatkan efisiensi pelatihan dan model. Augmentasi citra berfungsi untuk menambah jumlah data dari objek yang ada dan sama dalam bentuk artifisial melalui metode rotation, zoom, dan flipping [23], untuk meningkatkan variasi dataset dan mencegah overfitting. Setelah data siap dan disatukan dalam satu folder, selanjutnya dilakukan split data yaitu data training (70%), data validasi (20%) dan data testing (10%).

Pembangunan Model

Pembangun model dengan menerapkan metode CNN dengan transfer learning menggunakan arsitektur MobileNetV2 dengan bahasa Python, dan bantuan pustaka TensorFlow serta Keras. Layer awal dibekukan (frozen), kemudian ditambahkan GlobalAveragePooling2D, Dense layer 128 (ReLU), Dropout 0.3, dan Dense output layer (3 neuron + softmax) untuk klasifikasi yang ditunjukkan pada gambar 2. Proses pelatihan menggunakan 20 epoch, batch size 32, dan learning rate 0.001 dengan Callback yang digunakan yaitu EarlyStopping dan ReduceLROnPlateau. Parameter pelatihan ditentukan berdasarkan kombinasi referensi penelitian terdahulu dan uji coba awal (*trial experiment*). Nilai epoch 20-50 yang akan disesuaikan dengan hasil accuracy serta generalize model hingga overfitting dapat diminimalisirkan, batch size 32 digunakan untuk dataset menengah dan learning rate 0.001 dipilih sesuai rekomendasi penggunaan optimizer Adam. Model dikompilasi dengan optimizer Adam dan fungsi loss categorical_crossentropy. Model diuji menggunakan metrik akurasi, loss, precision, recall, dan f1-score serta confusion matrix.

Perhitungan Matematis

Perancangan model menggunakan metode CNN dengan arsitektur MobileNetV2 (transfer learning) diperlukan analisis dan validasi secara matematis. Perhitungan matematis dilakukan untuk menunjukkan efisiensi arsitektur MobileNetV2. Dengan menghitung jumlah parameter pada depthwise separable convolution, dense layer, dan fungsi aktivasi. Analisis ini menjadi dasar bahwa MobileNetV2 tepat digunakan untuk dataset terbatas. Perhitungan mencakup operasi dasar konvolusi [24], karakteristik depthwise separable convolution pada MobileNetV2 [25], proses pooling, perhitungan parameter dense layer, fungsi aktivasi softmax, perhitungan fungsi loss, serta algoritma optimasi [26] [27]. Setiap komponen memiliki kontribusi terhadap jumlah total parameter yang dilatih dan berpengaruh langsung terhadap kinerja model yang dibangun.

1. Operasi konvolusi (Ekstraksi Fitur) dengan persamaan $\text{Output} = \frac{(w-k+2p)}{s} + 1$ (1)

Berdasarkan persamaan 1, bahwa W diambil dari nilai lebar input, K merupakan nilai ukuran kernel, P nilai padding yang diberikan dan S merupakan nilai stride atau pergeseran kernel saat proses konvolusi berlangsung.

2. Depthwise Separable Convolution (MobileNetV2). Pada depthwise convolution, jumlah parameter dihitung menggunakan persamaan $Parameter = K \times K \times M$ (2)

Berdasarkan persamaan 2, mana K merupakan ukuran kernel dan M adalah jumlah channel input. Sementara itu, pada *pointwise convolution*, jumlah parameter dihitung dengan rumus $Parameter = 1 \times 1 \times M \times N$ (3)

Berdasarkan persamaan 3, M sebagai jumlah channel input dan N sebagai jumlah channel output.

3. Global Average Pooling (GAP)

GAP merupakan operasi yang dihitung rata-rata dari seluruh nilai piksel yang terdapat dalam *feature map* $GAP = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{ij}$ (4)

Berdasarkan persamaan 4, H sebagai tinggi *feature map*, W sebagai lebar *feature map*, dan x_{ij} sebagai nilai piksel pada posisi (i,j) .

4. Dense Layer (Fully Connected Layer)

Dense layer atau *fully connected layer* memiliki jumlah parameter yang dihitung menggunakan rumus:

$$Parameter = (Input \times Output) + Bias \quad (5)$$

Berdasarkan persamaan 5, *Input* adalah jumlah unit dari layer sebelumnya, *Output* adalah jumlah unit pada layer saat ini, dan *Bias* merupakan tambahan bias sebesar jumlah *Output*.

5. Aktivasi Softmax

Fungsi aktivasi *softmax* digunakan untuk mengubah output model menjadi bentuk probabilitas. Rumus *softmax* dinyatakan sebagai:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (6)$$

Berdasarkan persamaan 6, z_i adalah input ke- i , dan n adalah jumlah total kelas. Fungsi ini memastikan bahwa semua output berada dalam rentang 0 hingga 1 dan jumlah totalnya sama dengan 1, sehingga cocok digunakan dalam klasifikasi multi-kelas.

6. Fungsi Loss (Categorical Crossentropy)

Categorical Crossentropy Loss merupakan fungsi kerugian yang sering digunakan dalam masalah klasifikasi multi-kelas. Rumusnya dinyatakan sebagai:

$$Loss = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c}) \quad (7)$$

Berdasarkan persamaan 7, N adalah jumlah sampel, C adalah jumlah kelas, $y_{i,c}$ merupakan label sebenarnya (diberi nilai 1 jika sampel i termasuk dalam kelas c , dan 0 jika tidak), serta $\hat{y}_{i,c}$ adalah probabilitas prediksi model untuk kelas c pada sampel i .

7. Backpropagation dan Optimizer Adam

Proses *backpropagation* digunakan untuk memperbarui bobot model berdasarkan nilai gradien dari fungsi kerugian. Salah satu algoritma optimasi yang populer adalah *Adam Optimizer*. Rumus pembaruan bobot pada Adam dinyatakan sebagai:

$$\theta_{t+1} = \theta_t - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (8)$$

Berdasarkan persamaan 8, θ_t adalah parameter pada iterasi ke- t , α adalah laju pembelajaran (*learning rate*), $\hat{m}_t$ adalah estimasi rata-rata pertama (momentum), $\hat{v}_t$ adalah estimasi rata-rata kedua (variansi), dan ϵ adalah konstanta kecil untuk mencegah pembagian dengan nol.

Analisis dan Interpretasi Hasil

Deep learning memerlukan volume data yang sangat besar untuk hasil pelatihan yang efektif. Dikarenakan jumlah data dalam penelitian ini terbatas, oleh karena itu, penelitian ini mengacu pada skenario fine tuning yang ke-3 [28] [29] sesuai dengan Tabel 1 menggunakan metode Augmentasi dan proses fine tuning. Adapun pendekatan fine tuning dapat dilihat pada Tabel 1.

Tabel 1. Atribut Sumber Data

Skenario	Ukuran data target	Perbedaan domain data	Pendekatan
1	Kecil	Serupa	<i>Pre-trained as a feature extractor</i>
2	Besar	Serupa	<i>Fine tune through the full network</i>
3	Kecil	Sangat Berbeda	<i>Fine tune from activations earlier in the network</i>
4	Besar	Sangat Berbeda	<i>Fine tune through the entire network</i>

Berdasarkan tabel 1, data yang digunakan peneliti berbeda dengan database imagenet, baik dari segi domain dan karakteristik citra. Sehingga penelitian ini menggunakan skenario ke-3 yakni *fine tune from activations earlier in the network*, artinya bobot awal model MobileNetV2 yang telah dilatih pada ImageNet digunakan sebagai pre-trained model, yang kemudian disesuaikan (fine-tuning) menggunakan dataset citra objek wisata Kalbar. Adapun tujuannya alah agar mengambil pengetahuan dari ImageNet, tetapi tetap belajar mengenali pola data citra objek wisata. Evaluasi model dilakukan dengan metrik accuracy dan loss menggunakan model.fit dengan meampilkan training accuracy, training loss, validation accuracy dan validation loss setiap epoch. Selain itu dilakukan evaluasi mendalam dengan menggunakan confusion matrix, dengan laporan klasifikasi yakni Precision, Recall, dan f1-Score [30] [31]. Accuracy training dan loss menggunakan persamaan yang sama. Akurasi training dihitung sesuai jumlah prediksi benar oleh model berdasarkan data latih, dibagi dengan total jumlah sampel data latih. Demikian pula akurasi validasi dihiutng berdasarkan jumlah prediksi benar pada validasi dengan persamaan sebagai berikut:

$$Accuracy = \frac{Jumlah\ Prediksi}{Total\ Jumlah\ Data} \quad (9)$$

Sedangkan loss training dan validasi mengukur seberapa jauh prediksi model dari label yang benar, dalam hal ini peneliti menggunakan categorical crossentropy loss dengan persamaan sebagai berikut

$$Loss = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c}) \quad (10)$$

Berdasarkan persamaan 10, N merupakan jumlah sampel, C sebagai jumlah kelas, $y_{i,c}$ sebagai label asli (1 jika benar, 0 jika tidak), dan $\hat{y}_{i,c}$ sebagai prediksi probabilitas model untuk kelas

Evaluasi mendalam dengan precision, recall dan f-1 score. Precision merupakan sebuah prediksi positif terhadap suatu kelas

$$Precision = \frac{TP}{TP+FP} \quad (11)$$

Berdasarkan persamaan 11, recall mengukur kemampuan model dalam memprediksi dengan benar.

$$Recall = \frac{TP}{TP+FN} \quad (12)$$

Berdasarkan persamaan 12, F1-Score merupakan nilai mean dari precision dan recall

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (13)$$

III. HASIL DAN PEMBAHASAN

Hasil Pelatihan Model

Model dibangun menggunakan metode CNN berbasis transfer learning dengan arsitektur MobileNetV2 pada layer backbone (*feature extractor*) dibekukan (*Frozen*) dan hanya bagian classification head yang dilatih. Model dirancang untuk dapat melakukan tarining terhadap dataset objek di Kalimantan Barat yang telah melalui proses pelabelan manual. Dataset dibagi menjadi tiga bagian yakni tarining (70%), validasi (20) dan testing (10 Untuk mengurangi risiko *overfitting* serta meningkatkan variasi data, dilakukan proses augmentasi. Pelatihan model dilakukan menggunakan arsitektur MobileNetV2, dengan parameter *learning rate* sebesar 0.0010 dan jumlah epoch sebanyak 20. Hasil pelatihan menunjukkan nilai akurasi training dan validasi yang baik, yaitu sekitar 0,9, adapun rincian accura training da loss ditunjukkan pada Tabel 2.


Pembahasan

Nilai accuracy tarining dan validasi menunjukkan bahwa, pada epoch 1 atau epoch pertama accuracy tarining rendah (50.14%), hal ini normal dikarenakan merupakan baseline awal. Sedangkan accuracy validasi berada di nilai 67.70% yang berarti model mulai generalisasi mulai tahap awal. Epoch 2-5 nilai accuracy meningkat secara signifikan 80% - 90% dan accuracy validasi juga


mengalami peningkatan. Epoch 11-20 nilai akurasi konsisten berada diatas 90% dan nilai loss juga berada pada nilai sangat rendah yang menunjukkan model belajar dengan baik tanpa overfitting. Adapun grafik accuracy training dan accuracy validasi dapat dilihat pada Gambar 3. Evaluasi model dilakukan dengan metrik precision, recall, dan f1-score. Precision menggambarkan tingkat ketepatan model, yaitu proporsi prediksi positif yang benar dibandingkan seluruh prediksi positif. Recall menunjukkan tingkat keberhasilan model dalam menemukan data positif, yaitu proporsi prediksi benar dibandingkan seluruh data yang seharusnya positif. F1-score merupakan rata-rata harmonis antara precision dan recall, sedangkan support menunjukkan jumlah sampel pada setiap kelas. Hasil pengujian pada data uji (sebanyak 118 citra) menunjukkan bahwa model memiliki akurasi keseluruhan sebesar 89%, dengan nilai precision rata-rata 0.93, recall rata-rata 0.86, dan F1-score rata-rata 0.88. Beberapa kelas yang memiliki performa sangat baik adalah *Gua* (F1 = 1.00), *Riam* (F1 = 0.95), dan *Sungai* (F1 = 0.93). Sementara itu, kelas dengan performa relatif lebih rendah adalah *Hutan* (F1 = 0.80), *Pantai* (F1 = 0.81), dan *Budaya* (F1 = 0.86). Detail nilai per kelas ditunjukkan pada Gambar 4.

Tabel 2. Hasil Akurasi Training dan Validasi

Epoch	Training		Validasi		Learning Rate
	Accuracy	Loss	Accuracy	Loss	
1	0.2953	2.0654	0.3814	2.0994	0.0010
2	0.6220	1.1375	0.5085	1.3470	0.0010
3	0.7086	0.8974	0.5085	1.4237	0.0010
4	0.8066	0.6564	0.8882	1.0186	0.0010
...	...	...	...	...	...
18	0.9223	0.1852	0.8898	0.4824	0.0010
19	0.9439	0.2120	0.8729	0.5200	0.0010
20	0.9583	0.1365	0.8814	0.5323	0.0010



Gambar 3. Plot Akurasi




Gambar 4. Confusion Matrix

Implementasi Matematis Komponen Model


Dalam implementasi arsitektur MobileNetV2, analisis matematis diterapkan langsung pada parameter model yang digunakan. Berikut ini implementasi berdasarkan dataset dan lampiran arsitektur yang digunakan dalam pelatihan model :

1. Operasi Konvolusi (*Feature Extraction*)
Pada arsitektur MobileNetV2 dilayer awal, digunakan konvolusi kernel 3x3, padding 'same' dan stride 2 dengan nilai input gambar 224x224, sehingga output feature map dihitung
$$\text{Output} = \frac{(224 - 3 + 2 \times 1)}{2} + 1 = 112$$
2. Depthwise Separable Convolution (MobileNetV2) :
 - Depthwise convolution dengan kernel 3x3 pada input 32 channel sehingga
 $\text{Parameter} = 3 \times 3 \times 32 = 288$
 - Pointwise convolution output 64 channel sehingga
 $\text{Parameter} = 1 \times 1 \times 32 \times 64 = 2048$, sehingga diketahui bahwa total parameter layer ada 2048 parameter
3. Global Average Pooling (GAP) Layer GAP menurunkan feature map dari 7x7 menjadi nilai vektor sebesar 1280 fitur input ke dense layer.
4. Dense Layer (Fully Connected)
Dense (128): $1280 \times 128 + 128 = 163,968$
Dense (7) $128 \times 7 + 7 = 903$, sehingga total parameter pada classification head sebesar 164.871, sehingga fungsi aktivasi *softmax* menghasilkan probabilitas (kemungkinan) pada 7 kelas sebagai target prediksi model.
5. Fungsi Loss dihitung menggunakan *Categorical Crossentropy* sehingga nilai rata-rata loss pada epoch berjumlah 0.0558. sedangkan model optimasi menggunakan adam optimizer dengan learning rate 0.001.

Hasil perhitungan menunjukkan bahwa struktur MobileNetV2 dengan fine-tuning pada *classification head* mampu mengurangi kompleksitas model tanpa menurunkan akurasi. Total parameter yang dilatih sebesar 164.871 dibandingkan dengan jutaan parameter jika seluruh backbone dilatih, sehingga memberikan efisiensi pelatihan. Fungsi aktivasi softmax dan loss categorical crossentropy terbukti optimal pada dataset ini, serta Adam optimizer memungkinkan model mencapai konvergensi lebih cepat. Selanjutnya, model dievaluasi tidak hanya pada data training dan validasi, tetapi juga pada data testing untuk mengukur kemampuan generalisasi terhadap data baru (*unseen data*). Hasil pengujian menunjukkan bahwa akurasi test tetap tinggi dan konsisten dengan hasil validasi, didukung oleh nilai precision, recall, dan f1-score yang seimbang di setiap kelas. Setelah model klasifikasi objek wisata terbukti memiliki performa yang baik berdasarkan evaluasi training, validasi, dan testing, hasil klasifikasi diintegrasikan ke dalam pemetaan objek wisata. Pemetaan ini menampilkan persebaran objek wisata di Kalimantan Barat berbasis titik koordinat, dengan pembeda warna berdasarkan kategori, sehingga memudahkan interpretasi data. Visualisasi peta objek wisata dapat dilihat pada Gambar 5.



Gambar 5. Peta Objek Wisata



Gambar 6. Frekuensi Kategori Objek Wisata.

Dari dataset yang berhasil dikumpulkan, objek wisata tersebar di 12 kabupaten dan 2 kota. Kabupaten Bengkayang memiliki jumlah terbanyak, yaitu 39 objek wisata, didominasi oleh kategori bukit, pantai, dan riam. Contohnya adalah Bukit Jamur, Pantai Kura-Kura, dan Riam Merasap. Kabupaten Landak tercatat memiliki 18 objek wisata, didominasi air terjun dan riam seperti Air Terjun Engkanan dan Riam Sentagok. Kapuas Hulu dengan 14 objek, dikenal dengan air terjun dan danau seperti Danau Sentarum. Kabupaten lain seperti Sintang, Ketapang, Sanggau, Sambas, Melawi, dan kota Pontianak serta Singkawang memiliki beragam objek wisata mulai dari perbukitan, pantai, riam, hingga objek budaya. Pemetaan objek wisata ini didasarkan pada hasil kategori objek, berdasarkan hasil label manual. Hal ini sejalan dengan penelitian-penelitian sebelumnya yang menggabungkan klasifikasi citra dengan sistem informasi geografis, namun pada konteks pariwisata digital berbasis media sosial masih jarang dilakukan. Frekuensi tiap kategori objek wisata ditampilkan pada Gambar 8, yang menunjukkan bahwa kategori bukit, riam, dan pantai merupakan yang paling dominan serta persebaran objek wisata berdasarkan wilayah kabupaten/kota. Hasil ini memungkinkan kontribusi penelitian berupa peta wisata dapat digunakan untuk mendukung promosi, perencanaan, maupun pengambilan keputusan di bidang pariwisata.

IV. KESIMPULAN DAN SARAN

Penelitian ini berhasil membangun dan mengimplementasikan model klasifikasi objek wisata berbasis Convolutional Neural Network (CNN) dengan pendekatan transfer learning menggunakan arsitektur MobileNetV2 dan strategi fine-tuning. Dataset sebanyak 454 citra yang diperoleh dari Instagram telah melalui tahapan eliminasi, augmentasi, serta pelabelan manual sebelum dibagi menjadi data training (70%), validasi (20%) dan testing (10%). Model dilatih selama 20 epoch dengan learning rate 0.0010 menggunakan Adam Optimizer. Hasil pelatihan menunjukkan akurasi training mencapai 96%, validasi sebesar 88% dan testing sebesar 80% dengan nilai loss yang rendah, membuktikan efektivitas pelatihan dan minimnya overfitting. Evaluasi menggunakan precision, recall, dan f1-score menunjukkan performa klasifikasi yang sangat baik, didukung oleh confusion matrix yang menggambarkan akurasi seimbang di seluruh kelas. Secara matematis, implementasi model menunjukkan efisiensi parameter melalui penggunaan *Depthwise Separable Convolution*. Misalnya, layer *pointwise convolution* menghasilkan 2048 parameter, dan total parameter yang dilatih pada *classification head* adalah 164.871 jauh lebih ringan dibanding model konvensional. Hasil model ini kemudian diintegrasikan dalam sistem pemetaan interaktif berbasis titik koordinat, yang memvisualisasikan distribusi objek wisata di Kalimantan Barat. Pemetaan menunjukkan bahwa objek wisata kategori bukit, riam, dan pantai menjadi dominan, dengan persebaran terbanyak di Kabupaten Bengkayang dan Landak. Penelitian ini membuktikan bahwa CNN berbasis transfer learning efektif diterapkan untuk klasifikasi citra objek wisata dan dapat mendukung sistem informasi geografis berbasis data. Namun, keterbatasan jumlah dataset menjadi catatan penting. Oleh karena itu, pengembangan penelitian dengan perluasan cakupan data dan integrasi sistem *real-time* sangat dianjurkan untuk meningkatkan akurasi dan manfaat praktis.

DAFTAR PUSTAKA

- [1] A. R. Rinaldi, "BOROBUDUR DENGAN PENERAPAN KONSEP PARIWISATA NICHE DAN ALTERNATIF," vol. 7, no. 2, pp. 126–139, 2024.

- [2] H. Suyuthie, "Strategi Promosi Destinasi Wisata Pulau Angso Duo Kota Pariaman," pp. 78–84, 2024.
- [3] F. Satria, A. A. Purnomo, A. Maulana, and A. Hasibuan, "Open Access KECERDASAN BUATAN (AI) DALAM DUNIA INDUSTRI ARTIFICIAL INTELLIGENCE (AI) IN INDUSTRY," vol. 02, no. 01, pp. 253–262, 2025.
- [4] E. S. Eriana and D. A. Zein, "Artificial Intelligence," *Angew. Chemie Int. Ed.*, vol. 6(11), p. 1, 2023.
- [5] S. Liawatimena, *ARTIFICIAL INTELLIGENCE*, no. April. 2023.
- [6] D. Chrisinta and J. E. Simarmata, "Eksplorasi Teknik Web Scraping pada Data Mining: Pendekatan Pencarian Data Berbasis Python," *Fakt. Exacta*, vol. 17, no. 1, pp. 58–68, 2024, doi: 10.30998/faktorexacta.v17i1.22393.
- [7] A. Desia, "ANALISIS DESAIN KONTEN INSTAGRAM SEBAGAI STRATEGI PROMOSI @dkv.budiluhur," *Kartala*, vol. 2, no. 1, pp. 1–18, 2023, doi: 10.36080/kvs.v2i1.6.
- [8] A. Damayanti, I. D. Delima, and A. Suseno, "Pemanfaatan Media Sosial Sebagai Media Informasi dan Publikasi (Studi Deskriptif Kualitatif pada Akun Instagram @rumahkimkotatangerang)," *J. PIKMA Publ. Ilmu Komun. Media Dan Cine.*, vol. 6, no. 1, pp. 173–190, 2023, doi: 10.24076/pikma.v6i1.1308.
- [9] M. Sahu and R. Dash, "A Survey on Deep Learning: Convolution Neural Network (CNN) BT - Intelligent and Cloud Computing," 2021, pp. 317–325.
- [10] A. Tarafdar, A. I. Middy, S. Banerjee, S. Khatua, and S. Roy, "A CNN-based framework for land use land cover classification of heterogeneous terrain using satellite images," *Neural Comput. Appl.*, 2025, doi: 10.1007/s00521-025-11314-2.
- [11] E. Alnagi, A. Saif, and A. Ahmad, "A CNN-Based Model for Classifying Arabic Calligraphy Extracted from Images BT - Advances in Information and Communication," 2025, pp. 376–386.
- [12] M. H. V. Sinaga, M. Albirra, and M. F. Sidiq, "Klasifikasi Gambar Pemandangan dengan Kecerdasan Buatan Berbasis CNN," *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 8, no. 2, pp. 412–417, 2024, doi: 10.35870/jtik.v8i2.1424.
- [13] L. Hakim, H. R. Rahmanto, S. P. Kristanto, and D. Yusuf, "Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network," *J. Teknoinfo*, vol. 17, no. 1, p. 203, 2023, doi: 10.33365/jti.v17i1.2342.
- [14] C. N. Ihsan, "Klasifikasi Data Radar Menggunakan Algoritma Convolutional Neural Network (CNN)," *DoubleClick J. Comput. Inf. Technol.*, vol. 4, no. 2, p. 115, 2021, doi: 10.25273/doubleclick.v4i2.8188.
- [15] S. Davies and J. Jacob, "Novel algorithms for early cancer diagnosis using transfer learning with mobilenetv2 in thermal images," *KSII Trans. Internet Inf. Syst.*, vol. 18, no. 3, pp. 570–590, 2024, doi: 10.3837/tiis.2024.03.003.
- [16] M. Patel and M. Shah, "Transfer learning with fine-tuned deep CNN model for COVID-19 diagnosis from chest X-ray images," *Int. J. Adv. Technol. Eng. Explor.*, vol. 10, no. 103, pp. 720–740, 2023, doi: 10.19101/IJATEE.2022.10100044.
- [17] S. Dou, L. Wang, D. Fan, L. Miao, J. Yan, and H. He, "Classification of Citrus Huanglongbing Degree Based on CBAM-MobileNetV2 and Transfer Learning," *Sensors*, vol. 23, no. 12, pp. 1–18, 2023, doi: 10.3390/s23125587.
- [18] G. Gondhalekar, N. K. Bathala, N. B. Merugu, N. Joshi, P. L. Kumari, and S. S, "Enhancing Image Classification Performance through Transfer Learning and Adaptive Augmentation: A MobileNetV2 Approach," *SSRN Electron. J.*, 2025, doi: 10.2139/ssrn.5082255.
- [19] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustain.*, vol. 15, no. 3, 2023, doi: 10.3390/su15031906.
- [20] A. P. P. A. Majeed and A. Engelbrecht, *Transfer Learning: Leveraging the Capability of Pre-trained Models Across Different Domains*. IntechOpen, 2025. [Online]. Available: <https://books.google.co.id/books?id=jN9PEQAAQBAJ>
- [21] P. T. Huong, L. T. Hien, N. M. Son, H. C. Tuan, and T. Q. Nguyen, "Enhancing deep convolutional neural network models for orange quality classification using MobileNetV2 and data augmentation techniques," *J. Algorithms Comput. Technol.*, vol. 19, 2025, doi: 10.1177/17483026241309070.

- [22] S. Bouraya and A. Belangour, "Evaluating the Real-World Application Efficacy of MobileNet Models," *Int. J. Eng. Trends Technol.*, vol. 72, no. 9, pp. 197–202, 2024, doi: 10.14445/22315381/IJETT-V72I9P116.
- [23] M. F. Gunardi, "Implementasi Augmentasi Citra pada Suatu Dataset," *J. Inform.*, vol. 9, no. 1, pp. 1–5, 2023.
- [24] M. S. Dr. Eng. Novanti Yudistira, S.Kom., *Deep Learning : Teori, Contoh Perhitungan dan Implementasi*. Deepublish Digital, 2024. [Online]. Available: [https://books.google.co.id/books?id=G6cTEQAAQBAJ&lpg=PP1&ots=WreK4Rxkx7&dq=Perhitungan mencakup operasi dasar konvolusi &lr&pg=PR4#v=onepage&q&f=false](https://books.google.co.id/books?id=G6cTEQAAQBAJ&lpg=PP1&ots=WreK4Rxkx7&dq=Perhitungan+mencakup+operasi+dasar+konvolusi+&lr&pg=PR4#v=onepage&q&f=false)
- [25] J.-J. Shang, N. Phipps, I.-C. Wey, and T. H. Teo, "A-DSCNN: Depthwise Separable Convolutional Neural Network Inference Chip Design Using an Approximate Multiplier," *Chips - MDPI journals*, vol. 2, no. 3, pp. 159–172, 2023, doi: 10.3390/chips2030010.
- [26] J. Ghosh and S. Gupta, "ADAM Optimizer and CATEGORICAL CROSSENTROPY Loss Function-Based CNN Method for Diagnosing Colorectal Cancer," *Proc. Int. Conf. Comput. Intell. Sustain. Eng. Solut. CISES 2023*, no. April 2023, pp. 470–474, 2023, doi: 10.1109/CISES58720.2023.10183491.
- [27] A. G. I. L. Ferrer, "A neural network performance analysis with three different model structures," 2021.
- [28] M. Mira, I. Sembiring, and H. D. Purnomo, "Implementasi Transfer Learning Pada Algoritma Convolutional Neural Network untuk Mengklasifikasikan Image Objek Wisata," *Build. Informatics, Technol. Sci.*, vol. 4, no. 1, pp. 209–216, 2022, doi: 10.47065/bits.v4i1.1764.
- [29] B. Mira, S.Kom., M.Kom. , Candra Gudiato, S.Kom., M.Kom. , Bryan Chan, *Computer Vision dan YOLO Menggali Potensi Computer Vision dan Implementasi YOLO untuk Pertanian Pintar*. 2023.
- [30] A. Tasnim, M. Saiduzzaman, M. A. Rahman, J. Akhter, and A. S. M. M. Rahaman, "Performance Evaluation of Multiple Classifiers for Predicting Fake News," *J. Comput. Commun.*, vol. 10, no. 09, pp. 1–21, 2022, doi: 10.4236/jcc.2022.109001.
- [31] M. Conciatori, A. Valletta, and A. Segalini, "Improving the quality evaluation process of machine learning algorithms applied to landslide time series analysis," *Comput. Geosci.*, vol. 184, no. January, p. 105531, 2024, doi: 10.1016/j.cageo.2024.105531.