

Implementasi Transfer Learning Pada Algoritma Convolutional Neural Network untuk Mengklasifikasikan Image Objek Wisata

Mira^{1*}, Irwan Sembiring², Hindriyanto Dwi Purnomo³

Magister Sistem Informasi, Universitas Kristen Satya Wacana, Salatiga, Indonesia

Email: ^{1,*}972020004@student.uksw.edu, ²irwan@uksw.edu, ³hindriyanto.purnomo@uksw.edu

Email Penulis Korespondensi: 972020004@student.uksw.edu

Submitted: 25/06/2022; Accepted: 30/06/2022; Published: 30/06/2022

Abstrak—Penelitian ini mengklasifikasi image objek wisata dengan 9 label sky, tree, mountain, water, street, temple, garden, stone dan ricefield. Hasil labeling multi-label dapat digunakan untuk melihat frekuensi dan rekomendasi objek wisata di Jawa Tengah, dan membangun model transfer learning untuk mengetahui nilai akurasi. Pembangunan model menggunakan skenario fine tuning yang ketiga, yaitu data yang digunakan pada penelitian ini berbeda, jumlah data lebih sedikit dan domain data juga berbeda dari imagenet. Pengujian model menggunakan persamaan accuracy dan f1-core. Data train dan test dibagi menjadi 210, 290, 694 dan 1000 data. Klasifikasi dengan image multi-label memiliki kompleksitas tersendiri dalam proses labeling dan masih sedikit yang menggunakannya. Beberapa peneliti sebelumnya juga menyatakan semakin banyak jumlah data training dan jumlah epoch per step semakin tinggi akurasi yang dihasilkan. Berdasarkan hasil training dan evaluasi dari keempat data bahwa 210 data menunjukkan akurasi sebesar 0.8598 dengan loss 0.3245, sedangkan 290 data menunjukkan akurasi sebesar 0.8685 dengan loss 0.2903. Kemudian 594 data menunjukkan akurasi sebesar 0.8852 dengan loss 0.2756, dan 1000 data menunjukkan akurasi sebesar 0.8833 dengan loss 0.2863. Hal ini dapat menjawab pernyataan bahwa semakin banyak jumlah data akan semakin tinggi akurasi yang dihasilkan, sehingga model transfer learning pada arsitektur ResNet-50 dengan data image multi-label dapat diterapkan dengan menunjukkan hasil akurasi mendekati nilai akurasi pada ResNet-50 dalam project imagenet. Adapun potensi objek wisata di Jawa Tengah, yaitu objek wisata yang bertema alam, kemudian wisata hasil olahan tangan manusia seperti tempat bersejarah, cagar budaya dan tempat rekreasi keluarga.

Kata Kunci: Transfer Learning; Convolutional Neural Network; Klasifikasi; Multi-Label; Objek Wisata

Abstract—This study classifies the image of a tourist attraction with 9 labels sky, tree, mountain, water, street, temple, garden, stone and ricefield. The results of multi-label labeling can be used to see the frequency and recommendations of tourist attractions in Central Java, and build a transfer learning model to determine the accuracy value. The model development uses the third fine-tuning scenario, namely the data used in this study is different, the amount of data is less and the data domain is also different from imagenet. Testing the model using the equation of accuracy and f1-core. The train and test data are divided into 210, 290, 694 and 1000 data. Classification with multi-label images has its own complexity in the labeling process and few people use it. Several previous researchers also stated that the higher the amount of training data and the number of epochs per step, the higher the accuracy produced. Based on the results of training and evaluation of the four data, 210 data shows an accuracy of 0.8598 with a loss of 0.3245, while 290 data shows an accuracy of 0.8685 with a loss of 0.2903. Then 594 data shows an accuracy of 0.8852 with a loss of 0.2756, and 1000 data shows an accuracy of 0.8833 with a loss of 0.2863. This can answer the statement that the greater the amount of data, the higher the accuracy produced, so that the transfer learning model on the ResNet-50 architecture with multi-label image data can be applied by showing accuracy results approaching the accuracy value of ResNet-50 in the imagenet project. The potential for tourism objects in Central Java, namely tourism objects with the theme of nature, then tours processed by human hands such as historical places, cultural heritage and family recreation areas.

Keywords: Transfer Learning; Convolutional Neural Network; Classification; Multi-Label; Tourist Attraction

1. PENDAHULUAN

Wisata merupakan perjalanan mengunjungi satu tempat ke tempat lainnya, untuk mendapatkan hal baru, seperti suasana baru dan pengalaman baru. Berwisata dapat memberikan pengalaman dan perasaan yang berbeda terhadap wisatawan yang berkunjung. Beberapa dari kita, saat berwisata selalu membagikan momen melalui sosial media seperti *instagram*, *facebook*, *twitter* dan sosial media lainnya. Menurut SK NO.:KM 98/PW.102/MPP7-87, objek wisata merupakan keadaan alam yang memiliki daya tarik sumber daya wisata yang dikembangkan dan dibangun untuk dikunjungi oleh wisatawan.

Sebelum berwisata ke suatu tempat atau daerah, biasanya kita mencari referensi melalui sosial media sebagai referensi tujuan seperti tempat wisata yang sedang populer atau lebih banyak dikunjungi, atau malah memilih tempat wisata yang sedikit dikunjungi. Referensi wisata melalui media sosial dilakukan dengan melihat dari beberapa postingan orang lain, kemudian dilakukan analisis terhadap sebuah postingan, dengan tujuan mencari informasi pada sebuah postingan foto seperti lokasi dan nama tempat.

Namun tidak semua postingan memiliki informasi yang lengkap seperti nama tempat dan lokasi detail tempat wisata sehingga dilakukan beberapa upaya untuk mengetahui informasi terhadap sebuah postingan foto. Selain mencari referensi informasi dari beberapa postingan terdahulu, wisatawan juga dapat mencari informasi lain seperti tempat wisata, kuliner, dan sebagainya. Oleh karena itu, perlu dilakukan pengelompokan terhadap postingan foto untuk mengklasifikasi objek wisata. Klasifikasi dilakukan dengan pendekatan metode biner yang dikenal dengan logika 1,0 yaitu dengan memberi label data yang terkait dengan nilai 1 sedangkan data yang tidak terkait diberi nilai 0. Klasifikasi merupakan penyaringan data yang sesuai dengan nilai atau ciri-ciri yang sama[1]. Klasifikasi *Labeling image* terdiri dari *single-label* dan *multi-label*.

Klasifikasi *image single-label* dengan menggunakan arsitektur *Convolutional Neural Network* (CNN) telah banyak dilakukan, dan sudah terbukti memiliki nilai akurasi yang baik. Namun klasifikasi dengan *image multi-label* memiliki kompleksitas tersendiri dalam proses *labeling* dan masih sedikit yang menggunakannya. Dalam kasus dengan *image multi-label*, tantangan utama muncul karena variasi posisi objek yang berbeda serta *pose* dan skala yang berbeda[2]. Hal yang mempengaruhi kompleksitas saat *labeling multi-label* yaitu keselarasan latar objek, susunan spasial yang berbeda-beda besarnya meskipun benda-benda pada kedua bayangan tersebut sama [2].

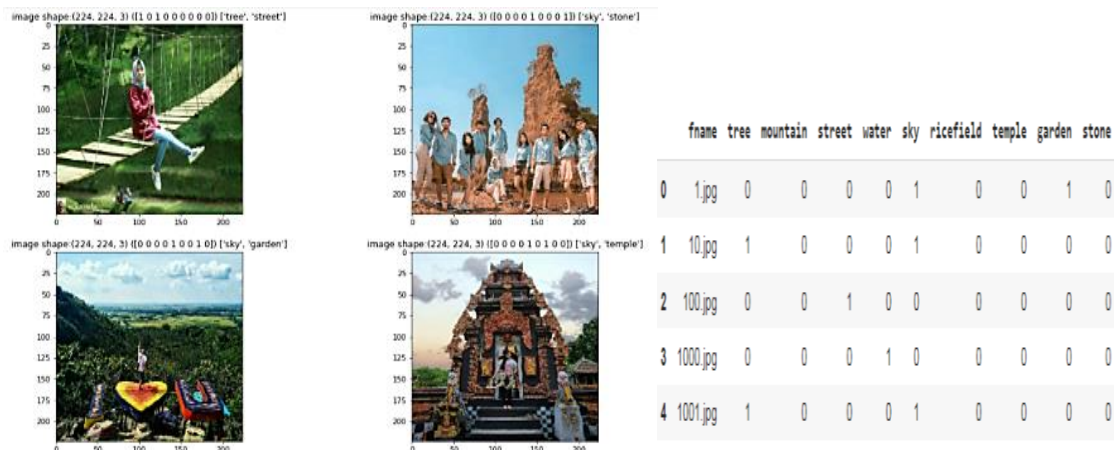
Klasifikasi *image* dengan teknik *labeling image multi-label* dapat menjadi pendekatan pembangunan database objek wisata, Selain dapat melakukan klasifikasi, pada penelitian ini juga menganalisis akurasi terhadap metode dan model yang dirancang, sebagai upaya untuk melihat kesesuaian metode, model dengan data yang dipilih. Kemudian hasil *labeling multi-label* dapat digunakan untuk melihat frekuensi dan rekomendasi objek wisata di Jawa Tengah melalui data *image* yang di *crawling* pada postingan *instagram* “*exploreateng_*”. Frekuensi yang dihasil sebagai upaya untuk mengetahui potensi objek wisata serta dapat menjadi referensi dan rekomendasi informasi dalam pengembangan dan promosi kepariwisataan di Jawa Tengah. Selain itu juga dapat digunakan untuk mengetahui klasifikasi potensi internal, eksternal dan potensi fisik masing-masing objek wisata dan dapat melihat minat wisatawan dalam berkunjung ke Jawa Tengah.

Penelitian dalam klasifikasi *image multi-label* yang merupakan pengembangan dari *image single-label* telah diteliti oleh Shahriyar dkk, (2019) dan Bariyah dkk (2021). Pada penelitian pertama menunjukkan akurasi penggunaan arsitektur *Convolutional Neural Network* (CNN) dalam melakukan klasifikasi *multi-label* pada 15 motif batik mencapai 91.41% dari 300 citra uji dengan menggunakan *epoch* 100. Sedangkan pada penelitian kedua, menggunakan data CIFAR-10 dan menghasilkan akurasi sebesar 51% sampai 57%. [3] [2]. Penelitian oleh Yuliani dkk (2021), Ratnawati (2018) dan Kane (2016) juga menyatakan semakin banyak jumlah data *training* dan jumlah *epoch per step* semakin tinggi akurasi yang dihasilkan[4] [5][6].

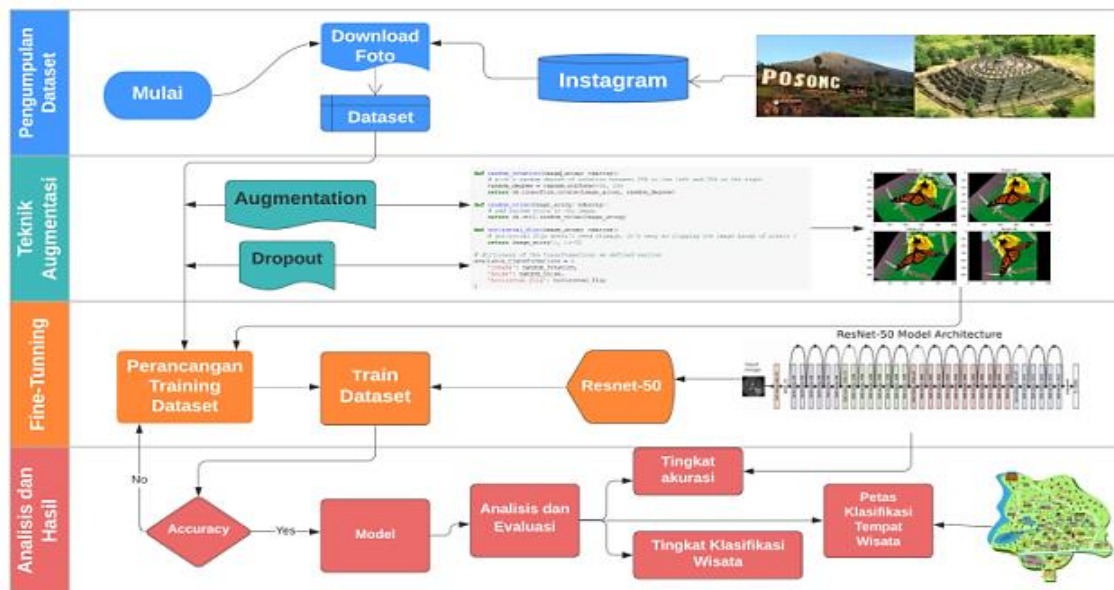
Berdasarkan hasil akurasi dari kedua peneliti, penelitian ini bertujuan untuk mengklasifikasikan 2094 data *image multi-label* dan membangun model *transfer learning* menggunakan salah satu arsitektur *Convolutional Neural Network* (CNN) yaitu ResNet-50, untuk melihat akurasi dari hasil data *image* objek wisata yang di *labeling*, guna untuk mengetahui kelas potensi objek wisata seperti objek wisata yang bertema alam, sejarah, cagar budaya dan tempat rekreasi. *Transfer learning* adalah model atau *neural network* yang sudah dilatih/*train* sebelumnya lalu mengurangi jumlah parameter dengan cara mengambil beberapa bagian dari model yang sudah dilatih untuk mengenal model baru [7][8]. ResNet-50 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) dengan konsep *shortcut connections*[9]. Model yang dibangun akan dilatih/*train* menggunakan data *image* wisata yang didapat menggunakan teknik *scraping* dari sebuah akun *instagram* yaitu “*exploreateng_*” untuk melihat potensi objek wisata. Kelas potensi objek wisata yang dapat dikategorikan berdasarkan objek wisata alam, budaya, sejarah, rekreasi dan dapat menjadi referensi database dalam pengembangan kepariwisataan dan rekomendasi potensi objek wisata di Jawa Tengah.

2. METODOLOGI PENELITIAN

Tahap penelitian dimulai dengan proses pengumpulan data, *filtering*, *labeling*, memilih dan membangun arsitektur *Convolutional Neural Network* (CNN) dan pengujian model yang terdiri dari nilai akurasi berdasarkan masing-masing jumlah data, dengan *epoch*, *batch size* (bs) dan *learning rate* (lr) yang disesuaikan dengan masing-masing jumlah data. Sedangkan evaluasi model menghitung nilai *accuracy* dan *micro F1-score*. Contoh data *image* dengan objek wisata yang digunakan pada penelitian ini dapat dilihat pada Gambar 1. Sedangkan desain penelitian digambarkan sebagaimana terdapat pada diagram alir pada Gambar 2.



Gambar 1. Model Data



Gambar 2. Kerangka Kerja Penelitian

2.1 Pengumpulan Data

Data penelitian ini merupakan data objek wisata dengan 2094 data image yang didapatkan dari *instagram* dengan akun “exploreateng_” menggunakan teknik *scraping*. *Web scraping* *instagram* merupakan teknik mengambil data dari *web* atau sosial media menggunakan barisan *script* yang dimengerti oleh komputer dan diolah menjadi sebuah informasi[10]. Data yang dikumpulkan kemudian di filter manual, dengan memilih *image* yang merupakan objek wisata, sedangkan untuk *image* dengan objek lainnya dihapus beserta video, sehingga menghasilkan *folder* yang hanya memiliki *image* dengan objek wisata. Setelah dilakukan *filtering*, selanjutnya mengimport data ke dalam *Microsoft Excel* menggunakan *script visual basic* untuk melakukan proses *labeling* manual. *Labeling* menggunakan teknik *multi-label* dikarenakan dalam *image* memiliki beberapa objek. Kombinasi dari *multilabel* data yang digunakan terdiri dari *tree, mountain, street, water, sky, ricefield, temple, garden* dan *stone*. Hasil *labeling* di simpan dengan format “*csv*”.

2.2 Preprocessing Image

Dalam *preprocessing* data, semua data *image* dengan objek wisata diubah ukurannya menjadi 224x224x3 untuk dilatih menggunakan teknik *transfer learning*. Ukuran *input image* yang digunakan harus sama dengan ukuran *input* pada model asli. Model ResNet-50 telah dilatih sebelumnya pada dimensi *input* 224x224[11] untuk tinggi dan lebar, dengan 3 saluran untuk *Red, Green, Blue* (RGB) dengan jumlah ratio 80%:20% dan 70%:30%. Sedangkan *batch size* yang digunakan yaitu 64, 32, 16, 8. untuk *Learning rate* 1e-3, penggunaan *batch size* dan *epoch* disesuaikan dengan jumlah data untuk menghasilkan akurasi yang maksimal.

Batch size merupakan hyperparameter yang menentukan jumlah sampel saat proses *training* berlangsung. Penentuan jumlah *batch size* dapat disesuaikan dengan jumlah data. Beberapa penelitian terkait mengenai jumlah *batch size* menggunakan dua pendekatan, yaitu[12] :

$$B_K \in \{16, 32, 64, 128, 256, 512, 1024\}, \text{ dan}$$

$$B_{ie} \in \{50, 100, 150, 200, 250\}.$$

Learning rate merupakan besaran langkah dalam menentukan *upgrade weight*. Saat proses *training* berlangsung, *grafik loss* tidak dapat dilihat sehingga tidak dapat ditentukan *learning rate* yang sesuai, oleh karena itu, diperlukan pencarian dengan mencoba dan mengikuti *learning rate* dari *network* yang pernah digunakan dengan jenis *network* yang sama. Selain itu dapat dilakukan dengan mencoba *learning rate* satu persatu dari 0,1 sampai dengan 0.05 yang umunya antara 1 sampai 0.

Epoch merupakan kondisi saat data inputan masuk ke dalam model dengan proses *forward propagation* dan *back propagation* dalam sekali putaran[9][13].

2.3 Pembangunan Model

Pembangunan model ini dilakukan dengan tahap memilih salah satu arsitektur *Convolutional Neural Network* (CNN). Dalam hal ini ResNet-50 menggunakan data yang terbagi menjadi *train* dan *test*. Pembangunan model menggunakan bahasa *Python* dan *Library Tensorflow* serta keras pada *google colab* dengan *runtime Graphics Processing Unit* (GPU).

2.4 Transfer Learning

Beberapa kondisi dalam menerapkan teknik *transfer learning* yaitu :

- Masalah data, *deep learning* [14] membutuhkan banyak data untuk bisa mendapatkan hasil yang baik. Selain itu dibutuhkan banyak waktu untuk mendapatkan data berlabel jika dilakukan oleh manusia dalam mengambil gambar dan memberi label satu-per-satu.
- Masalah komputasi, perlu dilakukan proses berulang untuk mendapatkan hasil yang memuaskan. Secara komputasi perlu menggunakan GPU untuk membantu proses *training neural network* dalam menggunakan ribuan bahkan puluhan ribu gambar yang membutuhkan waktu berhari-hari dan harga yang mahal.


Dalam *transfer learning* terdapat proses *fine tuning*, beberapa pendekatan *fine tuning* dapat dilihat pada Tabel 1 [17].

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 dipakai pada penelitian ini berbeda, sehingga digunakan skenario 3 dimana jumlah data lebih sedikit dari *imagenet*, domain data juga berbeda dan kemudian dilakukan pendekatan *fine tune from activations earlier in the network*. Adapun proses *fine tune* terdiri dari dua langkah yaitu :

- Adaptasi, yaitu proses *load model* dengan memilih salah satu arsitektur *Convolutional Neural Network (CNN)*. *Load model* untuk menghasilkan fitur *extraction* dari *input*, sehingga menghasilkan *image* yang lebih kecil. Setelah model di *load*, kemudian model di *freeze* atau dibekukan *weight/bobotnya*. Selanjutnya modifikasi *classifier* atau *fully connected (FC)* yang merupakan *classifier* atau *mini* arsitektur.
- Fine-tuning*, proses pada *fine tune* yaitu *unfreeze* *mini arsitektur/classifier*, kemudian lakukan *train* ulang terhadap data. Adapun proses *transfer learning* pada penelitian ini dapat dilihat pada Gambar 3.



Gambar 3. Transfer Learning

2.5 Pengujian dan Evaluasi

Pengujian model menggunakan data *testing*, pengujian data menggunakan data *loss* dan *accuracy*, kemudian dilanjutkan dengan menghitung *macro F1-Score*. Data *loss* digunakan untuk memaksimalkan kinerja algoritma pada model dalam proses *training*, sedangkan *accuracy* mengukur kinerja algoritma [3].

Loss function terdiri dari *Binary cross entropy*, *Cross-entropy* didefinisikan sebagai ukuran perbedaan antara dua distribusi probabilitas untuk variabel acak tertentu atau serangkaian peristiwa [15].

$$\text{BinaryCrossEntropy}(y, \hat{y}) = -(y \log(\hat{y}) + (1-y) \log(1-\hat{y})) \quad (1)$$

Micro F1-score (micro-averaged f1-score) untuk menilai kualitas masalah *multi-label*. *Micro f1-score* didapat dari *micro-precision* dan *micro-recall*. Perhitungan *micro f1-score* menggunakan persamaan 2. Proses rumus *micro* [16]

$$F1 \text{ Micro} = \frac{2 * P * R}{P + R} \quad (2)$$

Accuracy keseluruhan adalah rata-rata di semua *instance*. Nilai *accuracy* dapat dihitung menggunakan Persamaan 1[3].

$$\text{Accuracy} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{|Y_i \cup Z_i|} \quad (3)$$

Precision adalah proporsi prediksi label yang benar dengan jumlah total label sebenarnya, dirata-ratakan dari semua *instance*. Nilai *precision* dapat dihitung dengan Persamaan 2[3].

$$Precision, = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{|Z_i|} \tag{4}$$

Recall adalah proporsi label yang diprediksi benar dengan jumlah total label yang diprediksi, dirata-ratakan dari semua instance. Nilai recall dapat dihitung dengan Persamaan 3 [3].

$$Recall, = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{|Y_i|} + |Z_i| \tag{5}$$

F-Measure merupakan rata-rata precision dan recall harmonik). Nilai f-measure dapat dihitung dengan Persamaan 4 [3].

$$F\text{-Measure}, F_1 = \frac{1}{n} \sum_{i=1}^n \frac{2|Y_i \cap Z_i|}{|Y_i| + |Z_i|} \tag{6}$$


3. HASIL DAN PEMBAHASAN

Model yang dirancang digunakan untuk melatih data image dengan objek wisata dengan tiga channel RGB. Proses training data dibagi menjadi data train dan data test dengan jumlah 80:20% dan 70:30%. Pada proses training dataset dipecah menjadi 4 dataset dengan ukuran 210, 290, 594 dan 1000 data. Kemudian masing-masing data dilatih/training untuk mengetahui accuracy dan loss terhadap setiap data dengan learning rate dan epoch yang sama untuk setiap data, sedangkan jumlah batch size di sesuaikan dengan masing-masing jumlah data. Proses training data dilakukan dengan menggunakan Google Collab dengan Runtime GPU pada model arsitektur Convolutional Neural Network (CNN) yaitu ResNet-50. GPU berfungsi dapat meningkatkan kecepatan proses train. Adapun hasil training dari masing-masing data dengan function loss binary cross entropy dapat dilihat pada Tabel 2.

Tabel 2. Hasil Akurasi


Data & Ratio	Epoch	lr	Bs	RGB				
				Train		Test		
				Loss	Accuracy	Los	Accuracy	
210	0.8	50	1e-3	8	0.2875	0.8810	0.3245	0.8598
290	0.70	50	1e-3	16	0.2503	0.8927	0.2903	0.8685
594	0.80	50	1e-3	32	0.2974	0.8852	0.2756	0.8777
1000	0.80	50	1e-3	64	0.2783	0.8876	0.2863	0.8833

Berdasarkan Tabel 2, nilai accuracy dari setiap data terus mengalami peningkatan sedangkan loss mengalami penurunan. Adapun hasil accuracy dan loss dari 210 data menunjukkan accuracy sebesar 0.8598 dengan loss 0.3245 sebagaimana terdapat pada Gambar 4.




Gambar 4. Nilai Akurasi dan Loss 210 Data

Sedangkan nilai accuracy dan loss dari 290 data menunjukkan accuracy sebesar 0.8685 dengan loss 0.2903 mengalami peningkatan dari 210 data sebagaimana terdapat pada Gambar 5.




Gambar 5. Nilai Accuracy dan Loss 290 Data

Selanjutnya nilai accuracy dan loss dari 594 data menunjukkan nilai accuracy sebesar 0.8777 dengan loss 0.2756 mengalami peningkatan dari 210 dan 290 data sebagaimana terdapat pada Gambar 6.



Gambar 6. Nilai Accuracy dan Loss 594 Data

Kemudian 1000 data menunjukkan accuracy sebesar 0.8883 dengan loss 0.2863 sebagaimana terdapat pada Gambar 7.



Gambar 7. Nilai Accuracy dan Loss 1000 Data

Meskipun nilai accuracy dan loss pada data yang berjumlah 210 dan 290 mengalami selisih dengan jarak yang cukup banyak. Nilai accuracy dan loss yang baik berada pada train dan test data dengan jumlah 594 data dan 1000 data, dimana nilai akurasi train dan test mengalami peningkatan dari 0.8685 menjadi 0.8777, sedangkan nilai loss mengalami penurunan dari 0.2903 menjadi 0.2756. Pada 100 data nilai train mengalami peningkat dari 594 data dari 0.8777 menjadi 0.8833 dengan loss dari 0.2974 menjadi 0.2783.


Evaluasi model dengan menghitung micro f1-score pada masing-masing data dengan learning rate dan epoch yang sama, sedangkan batch size disesuaikan dengan masing-masing jumlah data dengan menggunakan tiga channel RGB (Red, Green, Blue). Hasil evaluasi model dengan micro f1-score yang menilai kualitas akurasi prediksi multi-label dari hasil precision dan recall, bahwa nilai loss pada setiap data rata-rata diatas 0.7. Hal ini di sebabkan dari proses labeling yang masih belum cukup benar dalam menentukan objek yang terkait. Adapun hasil evaluasi model terhadap masing-masing data dengan micro f1-score dapat dilihat pada Tabel 3.

Tabel 3. Hasil Mikro F1-Score

Data	Ratio	Bs	Lr	Epoch	RGB			
					Train		Test	
					Loss	Macro F1	Loss	Macro F1
210	0.8	8	1e-5	50	0.7505	0.2402	0.7640	0.2132
290	0.70	16	1e-5	50	0.7718	0.2206	0.7951	0.1719
594	0.80	32	1e-5	50	0.7569	0.2509	0.7633	0.2359
1000	0.80	64	1e-5	50	0.7628	0.2208	0.7674	0.2049


Berdasarkan Tabel 3, hasil prediksi menunjukkan masih terdapat beberapa kesalahan model dalam memprediksi, hal ini disebabkan oleh beberapa hal seperti kontras warna yang sama meskipun objek berbeda dan kesalahan dalam menentukan objek terkait selama proses labeling. Adapun contoh hasil prediksi klasifikasi multi-label pada image wisata dapat dilihat pada Tabel 4.

Tabel 4. Tabel Hasil Pengujian Model Convolutional Neural Network (CNN)

Fname	Image	Labeling	Prediksi
539.jpg		Mountain, Sky	Mountain, Sky

423.jpg		Tree	Tree
1321.jpg		Water	Tree, Water
1457.jpg		Water, Sky	Water, Sky
306.jpg		Sky	Sky

Proses *labeling image multi-label* menggunakan pendekatan logika *biner* yaitu 0,1. Dalam proses *labeling*, selain menentukan objek yang terkait, hal lain yang perlu diperhatikan seperti kontras warna antar *image* dengan objek yang sama dan berbeda, sehingga proses *labeling* dengan *image* yang lebih dominan ke langit daripada objek wisata diberi label “*sky*”. Adapun grafik frekuensi *labeling multi-label* dari keseluruhan data dengan jumlah 2094 data dapat dilihat pada Gambar 8.



Gambar 8. Frekuensi Kategori Objek Wisata

Berdasarkan hasil frekuensi, dari 2094 data *image* dengan 9 (Sembilan) kategori objek wisata didapatkan frekuensi dari yang paling sering muncul sampai yang paling sedikit yaitu *sky*, *tree*, *mountain*, *water*, *street*, *temple*, *garden*, *stone* dan *ricefield*. *Sky*, *tree*, *mountain*, *water* dan *stone* merupakan objek wisata alam, sedangkan *street*, *garden* dan *ricefield* merupakan objek wisata dari hasil olahan tangan manusia. Oleh karena itu dapat diketahui minat wisatawan dalam mengunjungi objek wisata di Jawa Tengah yaitu lebih banyak mengunjungi objek wisata yang bertema alam, kemudian dilanjutkan dengan kategori objek wisata dari hasil olah tangan manusia atau masyarakat setempat seperti taman dan tempat rekreasi keluarga

4. KESIMPULAN

Berdasarkan hasil *training* dan evaluasi dari keempat proses *training* data, dengan data pertama yang berukuran 210 dengan *batch size* 8, *learning rate* 1e-3 dan *epoch* 50 menunjukkan akurasi sebesar 0.8598 dengan *loss* 0.3245. Data yang berukuran 290 dengan *batch size* 16, *learning rate* 1e-3 dan *epoch* 50 menunjukkan akurasi sebesar 0.8685 dengan *loss* 0.2903. Data yang berukuran 594 dengan *batch size* 32, *learning rate* 1e-3 dan *epoch* 50 menunjukkan akurasi sebesar 0.8852 dengan *loss* 0.2756. Terakhir data yang berukuran 1000 dengan *batch size* 46, *learning rate* 1e-3 dan *epoch* 50 menunjukkan akurasi sebesar 0.8833 dengan *loss* 0.2863. Hasil akurasi dari keempat data dengan

jumlah data yang berbeda, bahwa nilai akurasi dan *loss* yang baik berada pada data dengan jumlah 594 dan 1000 data. Hal ini dapat menjawab beberapa pernyataan bahwa semakin banyak jumlah data akan semakin tinggi akurasi yang dihasilkan, sehingga model *transfer learning* dengan teknik *fine tuning* pada arsitektur *ResNet-50* dengan data *multi-label* dapat diterapkan dengan menunjukkan hasil akurasi mendekati dengan nilai akurasi pada *ResNet-50* dalam project *imagenet*. Adapun rekomendasi potensi objek wisata di Jawa Tengah, yaitu objek wisata yang bertema alam, kemudian wisata hasil olahan tangan manusia seperti tempat bersejarah, cagar budaya dan tempat rekreasi keluarga.

REFERENCES

- [1] D. Vaya and T. Hadpawat, "Classification in Data Mining : A Survey," vol. 29, no. 3, pp. 13072–13078, 2020.
- [2] S. A. Shahriyar, K. M. Rokibul Alam, S. S. Roy, and Y. Morimoto, "An Approach for Multi Label Image Classification Using Single Label Convolutional Neural Network," *2018 21st Int. Conf. Comput. Inf. Technol. ICCIT 2018*, no. December, 2019, doi: 10.1109/ICCITECHN.2018.8631970.
- [3] T. Bariyah, M. A. Rasyidi, and N. Ngatini, "Convolutional Neural Network untuk Metode Klasifikasi Multi-Label pada Motif Batik," *Techno.Com*, vol. 20, no. 1, pp. 155–165, 2021, doi: 10.33633/tc.v20i1.4224.
- [4] C. U. K. Enie Yuliani1, Afifah Nur Aini2, "Perbandingan Jumlah Epoch Dan Steps Per Epoch Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar," *J. Inf. Politek. Indonusa Surakarta ISSN*, vol. 5, no. 3, pp. 23–27, 2019.
- [5] F. Ratnawati, "Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Opini Film Pada Twitter," *INOVTEK Polbeng - Seri Inform.*, vol. 3, no. 1, p. 50, 2018, doi: 10.35314/isi.v3i1.335.
- [6] S. N. Kane, A. Mishra, and A. K. Dutta, "Preface: International Conference on Recent Trends in Physics (ICRTP 2016)," *J. Phys. Conf. Ser.*, vol. 755, no. 1, 2016, doi: 10.1088/1742-6596/755/1/011001.
- [7] J. Rozaqi, A. Sunyoto, and R. Arief, "Implementasi Transfer Learning pada Algoritma Convolutional Neural Network Untuk Identifikasi Penyakit Daun Kentang Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease," *Procedia Eng. Life Sci.*, vol. 1, no. 1, 2021, [Online]. Available: <https://press.umsida.ac.id/index.php/PELS/article/view/820/478>.
- [8] M. A. H. Abas, N. Ismail, A. I. M. Yassin, and M. N. Taib, "VGG16 for plant image classification with transfer learning and data augmentation," *Int. J. Eng. Technol.*, vol. 7, no. 4, pp. 90–94, 2018, doi: 10.14419/ijet.v7i4.11.20781.
- [9] F. Nashrullah, S. Adhi, and G. Budiman, "Investigasi Parameter Epoch Pada Arsitektur ResNet- 50 Untuk Klasifikasi Pornografi," *J. Comput. Electron. Telecommun.*, vol. 1, no. 1, pp. 1–8, 2020.
- [10] B. Zhao, "Encyclopedia of Big Data," *Encycl. Big Data*, no. December, 2020, doi: 10.1007/978-3-319-32001-4.
- [11] R. Wightman, H. Touvron, and H. Jégou, "ResNet strikes back: An improved training procedure in timm," *Cornel Univ.*, vol. 1, no. october, pp. 1–22, 2021, [Online]. Available: <http://arxiv.org/abs/2110.00476>.
- [12] P. M. Radiuk, "Impact of Training Set Batch Size on the Performance of Convolutional Neural Networks for Diverse Datasets," *Inf. Technol. Manag. Sci.*, vol. 20, no. 1, pp. 20–24, 2018, doi: 10.1515/itms-2017-0003.
- [13] T. Bezdán and N. Bačanin Džakula, "Convolutional Neural Network Layers and Architectures," *Int. Sci. Conf. Inf. Technol. DATA Relat. Res.*, no. January, pp. 445–451, 2019, doi: 10.15308/sinteza-2019-445-451.
- [14] V. Kumar and M. L., "Deep Learning as a Frontier of Machine Learning: A Review," *Int. J. Comput. Appl.*, vol. 182, no. 1, pp. 22–30, 2018, doi: 10.5120/ijca2018917433.
- [15] S. Jadon, "A survey of loss functions for semantic segmentation," *IEEE Access*, vol. 2, no. 11, 2020.
- [16] G. Tika and Adiwijaya, "Klasifikasi Topik Berita Berbahasa Indonesia Menggunakan Multilayer Perceptron," *e-Proceeding Eng.*, vol. 6, no. 2, p. 2137, 2019.
- [17] Elgendy, M.(2019). Deep Learning for Vision System. 475.