

## KLASIFIKASI GAMBAR DALAM DAN LUAR RUANGAN DENGAN METODE CNN DAN HYPERBAND

I Made Anditya Mahesastra<sup>1</sup>, I Dewa Made Bayu Atmaja Darmawan<sup>2</sup>, I Gusti Agung Gede Arya Kadyanan<sup>3</sup>

### ABSTRAK

Pada suatu sistem yang menerima masukan item dan kategori dari item tersebut dari penggunaannya akan menjadi lebih efisien apabila diikuti dengan diterapkannya otomasi. Apabila sistem tersebut tidak disertai dengan fitur otomasi, proses tersebut cenderung akan memakan waktu. Untuk dapat menyelesaikan permasalahan tersebut, diperlukan teknik untuk melakukan otomasi pada proses kategorisasi gambar yang dilakukan pengguna. Teknik yang dapat digunakan adalah dengan membangun model *machine learning* yang akan dapat membedakan gambar dalam ruangan dan luar ruangan, sehingga proses kategorisasi gambar pada sistem yang menerapkan konsep ini dapat dilakukan secara efisien. Model kategorisasi pada penelitian ini dibangun menggunakan *Convolutional Neural Network* dan di optimasi menggunakan Hyperband.

**Kata kunci :** *Image Processing, Scene Classification, CNN, Hyperparameter Tuning, Hyperband Tuner.*

### ABSTRACT

In a system that receives input items and categories of these items from users, it will be more efficient if followed by the implementation of automation. If the system is not accompanied by automation features, the process tends to be time-consuming. To solve these problems, a technique is needed to automate the image categorization process by the user. The technique that can be used is to build a machine learning model that can distinguish indoor and outdoor images so that the image categorization process on systems that apply this concept can be carried out efficiently. The categorization model in this study was built using Convolutional Neural Network and optimized using Hyperband.

**Keywords:** *Image Processing, Scene Classification, CNN, Hyperparameter Tuning, Hyperband Tuner.*

### 1. PENDAHULUAN

Di masa kini, tak jarang suatu sistem memiliki fitur yang akan menerima masukan gambar dan masukan kategori dari penggunaannya. Apabila sistem tersebut tidak disertai dengan fitur otomasi,

---

<sup>1</sup> Mahasiswa Prodi Informatika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Udayana Badung 80362 Bali andimahesastra@email.com

<sup>1</sup> Staf Pengajar Prodi Informatika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Udayana Badung 80362 Bali dewabayu@unud.ac.id

<sup>1</sup> Staf Pengajar Prodi Informatika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Udayana Badung 80362 Bali gungde @unud.ac.id


## Klasifikasi Gambar Dalam Dan Luar Ruang Dengan Metode Cnn Dan Hyperband

proses tersebut cenderung akan memakan waktu dikarenakan proses kategorisasi gambar dilakukan secara manual oleh penggunanya. Dan apabila gambar yang dapat diterima serta kategori yang tersedia untuk dipilih sangat beragam, maka sistem tersebut akan memiliki efisiensi yang rendah. Untuk dapat menyelesaikan permasalahan tersebut, diperlukan teknik untuk melakukan otomatisasi pada proses kategorisasi gambar yang dilakukan pengguna. Teknik yang dapat digunakan adalah dengan membangun model *machine learning* yang akan mampu untuk mengategorikan gambar yang dimasukkan pengguna atau dapat disebut juga dengan model *scene classification*. *Scene Classification* adalah tugas di mana foto diklasifikasikan secara kategoris [1]. Tidak seperti klasifikasi objek, yang berfokus pada mengklasifikasikan objek yang menonjol di latar depan, Klasifikasi Pemandangan menggunakan tata letak objek di dalam pemandangan, selain konteks sekitar, untuk klasifikasi. Model yang dibangun pada penelitian ini adalah model yang akan dapat membedakan gambar dalam ruangan dan luar ruangan, sehingga proses kategorisasi gambar pada sistem yang menerapkan konsep ini dapat dilakukan secara efisien. Model kategorisasi pada penelitian ini dibangun menggunakan *convolutional Neural Network* (CNN). Metode *deep learning*, khususnya *deep convolutional neural network* (CNNs), telah mencapai sukses besar dalam banyak tugas visi komputer, terutama dalam pengenalan visual [2].

Ada pula beberapa penelitian lain yang meneliti kasus yang serupa dengan penelitian ini, contohnya pada penelitian [3], yaitu *scene classification* menggunakan metode CNN yang menggunakan data Places365-Standard *scene dataset*, yang terdiri atas 365 kategori dan mengandung 1.6 juta gambar sebagai data latih, 365 x 50 data gambar sebagai data validasi, dan 365 x 900 data gambar sebagai data tes, dengan hasil yang didapat adalah model dengan akurasi pelatihan sebesar 62.01, dan akurasi validasi sebesar 38.76. Selain itu, ada pula penelitian [4], yaitu *road scene classification* berdasarkan gambar tingkat jalan dan data spasial yang menggunakan data sebanyak 2.5 juta gambar yang terdiri atas 205 kategori, dengan hasil yang didapat adalah model dengan akurasi sebesar 0.86.

## 2. METODE PELAKSANAAN

Penelitian ini diawali dengan tahap persiapan data, *dataset* yang digunakan pada penelitian ini adalah DIODE (*Dense Indoor and Outdoor Depth*). *Dataset* tersebut akan di *preprocess* sebelum digunakan lebih lanjut untuk melatih model. Hal yang akan dilakukan di antaranya adalah *rescaling*, *augmenting*, dan *resizing*. Langkah selanjutnya adalah melakukan *hyperparameter tuning*, *hyperparameter tuning* adalah proses yang bertujuan untuk menemukan kombinasi yang tepat dari *hyperparameter* yang digunakan saat membangun model. *Hyperparameter tuning* pada penelitian ini menggunakan teknik *Hyperband*. Langkah selanjutnya adalah melatih model dengan kombinasi *hyperparameter* tersebut. Model ini dibangun menggunakan algoritma CNN, dengan *RMSprop optimizer*, dan *Binary Crossentropy loss function*. Langkah terakhir adalah evaluasi dari model yang telah dilatih tersebut, metrik yang digunakan sebagai nilai performa dari model yang digunakan pada penelitian ini adalah akurasi.



Gambar 2.1. Alur Penelitian

### 2.1. Persiapan Data

*Dataset* yang digunakan pada penelitian ini bersifat sekunder. *Dataset* yang digunakan pada penelitian ini adalah DIODE (*Dense Indoor and Outdoor Depth*), adalah kumpulan data yang berisi beragam gambar berwarna beresolusi tinggi dengan pengukuran kedalaman jarak jauh yang akurat,

padat. *Dataset* ini adalah kumpulan data publik pertama yang menyertakan gambar RGBD dari pemandangan dalam dan luar ruangan yang diperoleh dengan satu rangkaian sensor. *Dataset* ini berisikan 12.947 gambar RGB yang terbagi ke dalam 2 kelas (*indoor* dan *outdoor*). *Dataset* ini memiliki afiliasi dengan TTI-Chicago, University of Chicago, dan Beihang University.

*Dataset* tersebut akan di *preprocess* sebelum digunakan lebih lanjut untuk melatih model. Hal yang akan dilakukan di antaranya adalah *rescaling*, *augmenting*, dan *resizing*. *Rescaling* adalah tahap normalisasi data gambar yang semulanya memiliki *range* nilai dari 0 hingga 255, menjadi 0 hingga 1. *Augmenting* adalah tahap yang bertujuan untuk membuat beberapa gambar baru yang di proses menggunakan referensi gambar semula dengan tujuan untuk menambah data yang ada dengan harapan performa model menjadi lebih baik. Ada korelasi yang kuat antara kinerja operasi augmentasi data dalam *supervised learning* dan kinerjanya dalam consistency training [5]. Proses yang dilakukan pada tahap *augmenting* di antaranya adalah *random rotation*, *random zooming*, *random height shifting*, dan *random width shifting*. *Resizing* adalah tahap yang bertujuan untuk melakukan penyesuaian pada skala tiap gambar menjadi ukuran yang seragam agar *input shape* model yang akan dibangun dapat ditentukan.

## 2.2. Optimasi Hiperparameter

*Hyperparameter tuning* adalah proses yang bertujuan untuk menemukan kombinasi yang tepat dari *hyperparameter* yang digunakan saat membangun model. *Hyperparameter tuning* adalah alat yang sangat dibutuhkan sehingga semua platform cloud utama menawarkan alat penyetelan parameter [6]. *Hyperparameter tuning* pada penelitian ini menggunakan teknik Hyperband. Hyperband adalah metode yang relatif baru untuk menyetel algoritma *iterative*, teknik ini melakukan pengambilan sampel acak dan mencoba untuk mendapatkan keunggulan dengan menggunakan waktu yang dihabiskan untuk mengoptimalkan dengan cara terbaik. Hyperband, bergantung pada strategi penghentian awal yang berprinsip untuk mengalokasikan sumber daya, yang memungkinkannya untuk mengevaluasi lebih banyak konfigurasi pesanan daripada prosedur *black-box* seperti metode *Bayesian optimization* [7]. *Hyperparameter* yang akan di *tuning* di antaranya adalah jumlah filter dari *convolution layer*, jumlah dari pasangan *convolution layer* dan *maxpooling layer*, serta *learning rate*.

## 2.3. Pelatihan Model

Setelah proses pencarian kombinasi *hyperparameter* terbaik menggunakan teknik Hyperband, langkah selanjutnya adalah melatih model dengan kombinasi *hyperparameter* tersebut. Model ini dibangun menggunakan algoritma CNN. *Convolutional Neural Network* (CNN) memanfaatkan lapisan dengan filter konvolusi yang diterapkan pada fitur lokal [8]. Kemudian *RMSprop optimizer* adalah fungsi optimasi yang digunakan pada model ini. RMSProp adalah pengoptimal kecepatan pembelajaran adaptif yang tidak dipublikasikan yang diusulkan oleh Geoff Hinton. Motivasinya adalah besarnya gradien dapat berbeda untuk bobot yang berbeda, dan dapat berubah selama pembelajaran, sehingga sulit untuk memilih satu tingkat pembelajaran global [9]. Selanjutnya *Binary Crossentropy loss function* adalah fungsi kerugian yang digunakan pada model ini. Cross-entropy adalah fungsi yang mengukur seberapa jauh dari nilai sebenarnya prediksi untuk masing-masing kelas dan kemudian rata-rata kesalahan kelas bijaksana untuk mendapatkan kerugian akhir [10].

## 2.4. Evaluasi Model

Langkah terakhir adalah evaluasi dari model yang telah dilatih tersebut, metrik yang digunakan sebagai nilai performa dari model yang digunakan pada penelitian ini adalah akurasi. Akurasi adalah jumlah prediksi yang benar dibagi jumlah total prediksi.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Persiapan Data

*Dataset* yang digunakan pada penelitian ini bersifat sekunder. *Dataset* yang digunakan pada penelitian ini adalah DIODE (*Dense Indoor and Outdoor Depth*). *Dataset* ini berisikan 12.947 gambar RGB yang terbagi ke dalam 2 kelas (*indoor* dan *outdoor*). Sampel dari *dataset* ini di tunjukan pada Gambar 3.1.1.



**Gambar 3.1.1.** Contoh *Dataset* DIODE

*Dataset* tersebut kemudian akan di *preprocess* sebelum digunakan lebih lanjut untuk melatih model. Hal yang akan dilakukan di antaranya adalah *rescaling*, *augmenting*, dan *resizing*. Sampel dari *dataset* yang telah di *preprocess* di tunjukan pada Gambar 3.1.2.



**Gambar 3.1.2.** Contoh *Dataset* DIODE Setelah dilakukan *Preprocessing*

#### 3.2. Optimasi Hiperparameter

*Hyperparameter tuning* adalah proses yang bertujuan untuk menemukan kombinasi yang tepat dari *hyperparameter* yang digunakan saat membangun model. *Hyperparameter tuning* pada penelitian ini menggunakan teknik Hyperband. Hasil dari penerapan Hyperband dalam melakukan *hyperparameter tuning* di tunjukan pada Tabel 3.2.1.


**Tabel 3.2.1.** Kombinasi *Hyperparameter* Terbaik

No.	Hyperparameter	Value
1.	num_conv	1
2.	num_dense	1
3.	learning_rate	0.0001
4.	C2D_1_filters	16
5.	C2D_2_filters	8

6.	dense_1_units	16
7.	dense_2_units	8
8.	tuner/epochs	60
9.	tuner/initial_epoch	20
10.	tuner/bracket	3
11.	tuner/round	3
12.	tuner/trial_id	0046
13.	Score	0.8117284178733826

### 3.3. Pelatihan Model

Setelah proses pencarian kombinasi *hyperparameter* terbaik menggunakan teknik Hyperband, langkah selanjutnya adalah melatih model dengan kombinasi *hyperparameter* tersebut. Hasil dari pelatihan model di tunjukan pada Gambar 3.3.1.



Gambar 3.3.1. Hasil Pelatihan Model dengan Kombinasi *Hyperparameter* Terbaik

### 3.4. Evaluasi Model


Langkah terakhir adalah evaluasi dari model yang telah dilatih tersebut, metrik yang digunakan sebagai nilai performa dari model yang digunakan pada penelitian ini adalah akurasi. Akurasi adalah jumlah prediksi yang benar dibagi jumlah total prediksi. Data yang digunakan untuk mengevaluasi model adalah 20% dari total data yang tersedia. Akurasi akhir yang didapat setelah menguji model menggunakan *subset* dari *dataset* DIODE menunjukkan nilai 0.8228.

### 3.5. Contoh Penggunaan Model

Contoh cara penggunaan model yang telah dibangun dalam melakukan prediksi di tunjukan pada Gambar 3.5.1. Langkah-langkah yang diperlukan yaitu pertama-tama pengguna perlu memuat gambar ke dalam sistem. Langkah selanjutnya yaitu sistem akan mengubah gambar tersebut menjadi bentuk array yang nilainya akan merepresentasikan gambar tersebut berdasarkan nilai RGB nya. Langkah terakhir model akan melakukan prediksi terhadap array tersebut sehingga memberikan keluaran kategori. Sistem yang dibangun telah menggunakan kode program sesuai dengan yang ditunjukkan pada Gambar 3.5.1 dalam melakukan prediksi. Detail dari sistem tidak dijelaskan lebih rinci dikarenakan hal tersebut berada di luar dari cakupan penelitian ini.

## Klasifikasi Gambar Dalam Dan Luar Ruangan Dengan Metode Cnn Dan Hyperband

```
1 # preview uploaded image
2 import matplotlib.pyplot as plt
3 import matplotlib.image as mpimg
4 filename = f'/content/{list(uploaded.keys())[0]}'
5 img = mpimg.imread(filename)
6 imgplot = plt.imshow(img)
7 plt.grid(False)
8 plt.show()
```



```
[39] 1 # image to array
      2 from PIL import Image
      3 img = Image.open(filename)
      4 np_img = np.array(img)
      5 np_img = np.expand_dims(np_img, axis=0)
      6 np_img = np.vstack([np_img])
      7
      8 print(np_img.shape)
```

```
(1, 768, 1024, 3)
```

```
[40] 1 # model predict
      2 cname = ['outdoor', 'indoor']
      3 cname[int(loader_tuned_model.predict(np_img))]
```

```
1/1 [=====] - 0s 20ms/step
'indoor'
```

**Gambar 3.3.5.** Cara Penggunaan Model

## 4. KESIMPULAN

Penelitian ini bertujuan untuk membangun model yang dapat membedakan gambar dalam ruangan dan luar ruangan, sehingga proses kategorisasi gambar pada sistem yang menerapkan konsep ini dapat dilakukan secara efisien. Model kategorisasi pada penelitian ini dibangun menggunakan *convolutional Neural Network (CNN)*. *Dataset* yang digunakan pada penelitian ini adalah *DIODE (Dense Indoor and Outdoor Depth)*, adalah kumpulan data yang berisi beragam gambar berwarna beresolusi tinggi dengan pengukuran kedalaman jarak jauh yang akurat, padat. Dilakukan proses augmentasi pada data yang tersedia guna mengoptimalkan kinerja model dalam melakukan prediksi, metode augmentasi yang digunakan di antaranya adalah *rescaling*, *augmenting*, dan *resizing*. Dilakukan proses *hyperparameter tuning* pada model guna mencari kombinasi *hyperparameter*

terbaik, hasil dari penerapan Hyperband dalam melakukan *hyperparameter tuning* menghasilkan akurasi terbaik pada model dengan kombinasi *hyperparameter* seperti yang ditunjukkan pada Tabel 3.2.1. Skor yang didapat setelah melakukan proses *hyperparameter tuning* adalah sebesar 0.8117 dengan metric yang digunakan adalah akurasi. Selanjutnya akurasi akhir yang didapat setelah menguji model menggunakan *subset* dari *dataset* DIODE menunjukkan nilai 0.8228.

## UCAPAN TERIMA KASIH

Ucapan terima kasih penulis sampaikan kepada setiap pihak yang telah terlibat dalam membantu menyelesaikan jurnal pengabdian ini sehingga dapat dipublikasikan, pihak-pihak yang terlibat di antaranya:

1. Bapak Ida Bagus Made Mahendra, S.Kom., M.Kom. sebagai direktur CV. Avatar Solutions yang telah memberikan kesempatan bagi penulis untuk terlibat dalam pembangunan model *machine learning* sebagai salah satu fitur dari sistem booking ruangan yang dibangun.
2. Ibu Ni Kadek Ratna Sari, S.Kom sebagai project manager CV. Avatar Solutions dan pembimbing lapangan yang telah memberikan bantuan kepada penulis dalam perancangan konsep model *machine learning* yang dibangun.
3. Bapak I Dewa Made Bayu Atmaja Darmawan, S.Kom., M.Cs. sebagai dosen pembimbing yang telah memberikan saran dalam penyusunan jurnal ini.

## DAFTAR PUSTAKA

- [1] K. Koutini, H. Eghbal-zadeh, M. Dorfer, and G. Widmer, "The Receptive Field as a Regularizer in Deep Convolutional Neural Networks for Acoustic Scene Classification," Jul. 2019, [Online]. Available: <http://arxiv.org/abs/1907.01803>
- [2] Q. Wang, J. Xie, W. Zuo, L. Zhang, and P. Li, "Deep CNNs Meet Global Covariance Pooling: Better Representation and Generalization," Apr. 2019, doi: 10.1109/TPAMI.2020.2974833.
- [3] J. King, V. Kishore, and F. Ranalli, "Scene classification with Convolutional Neural Networks."
- [4] R. Prykhodchenko and P. Skruch, "Road scene classification based on street-level images and spatial data," *Array*, vol. 15, Sep. 2022, doi: 10.1016/j.array.2022.100195.
- [5] Q. Xie, Z. Dai, E. Hovy, M.-T. Luong, and Q. v. Le, "Unsupervised Data Augmentation for Consistency Training," Apr. 2019, [Online]. Available: <http://arxiv.org/abs/1904.12848>
- [6] R. Turner *et al.*, "Bayesian Optimization is Superior to Random Search for Machine Learning Hyperparameter Tuning: Analysis of the Black-Box Optimization Challenge 2020," Apr. 2021, [Online]. Available: <http://arxiv.org/abs/2104.10201>
- [7] L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, and A. Talwalkar, "Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization," Mar. 2016, [Online]. Available: <http://arxiv.org/abs/1603.06560>
- [8] Y. Kim, "Convolutional Neural Networks for Sentence Classification," Aug. 2014, [Online]. Available: <http://arxiv.org/abs/1408.5882>

#### **Klasifikasi Gambar Dalam Dan Luar Ruang Dengan Metode Cnn Dan Hyperband**

- [9] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," Dec. 2015, [Online]. Available: <http://arxiv.org/abs/1512.00567>
- [10] P. Brahmhatt and S. Nath Rajan, "Skin Lesion Segmentation using SegNet with Binary Cross-Entropy," 2019.