

## Optimalisasi Kinerja Convolutional Neural Networks VGG16 dalam Identifikasi Bangunan Adat Melayu

Sri Winiarti<sup>1</sup>, Sunardi<sup>2</sup>, Abdul Fadlil<sup>3</sup>

<sup>1</sup>Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia, 55191

<sup>2,3</sup>Teknik Elektro, Universitas Ahmad Dahlan, Yogyakarta, Indonesia, 55191

e-mail: <sup>1</sup>sri.winiarti@tif.uad.ac.id, <sup>2</sup>sunardi@mti.uad.ac.id, <sup>3</sup>fadlil@mti.uad.ac.id

Submitted Date: June 03, 2025

Reviewed Date: June 17, 2025

Revised Date: June 21, 2025

Accepted Date: July 03, 2025

### Abstract

The use of deep learning in detecting various objects has been widely applied, but for identifying building similarities for architectural styles is still limited. Classification analysis of architectural design models of traditional Malay buildings can be done by applying the Convolutional Neural Network (CNN) method. The approach used to analyze the classification and similarity of traditional Malay building models uses the VGG16 architectural model. Feature extraction utilizes a deep learning model to identify the type of traditional Malay building based on roof, window, and building ornament parameters. The image dataset of traditional Malay buildings was obtained from direct collection at the location of the Riau Traditional Malay Building in the Muhammad Arifin Street area of Pekanbaru, Riau, for training as many as 644 images and testing the model with as many as 106 images. The model used is VGG16. Performance measurement parameters include accuracy, precision, recall, and F1-score. The accuracy obtained in this study was 98.77% of the total 106 data points tested, while the precision was 0.8678, the recall was 0.9633, and the F1-score was 0.9877. The results obtained were obtained by setting the learning rate parameters to 0.0001, dropout to 0.20, and epoch to 25. Overall, the VGG16 model used in this study produced good accuracy.

**Keywords:** Malay Traditional Buildings; Convolutional Neural Network; Identification; Optimization; VGG16 Model.

### Abstrak

Penggunaan *deep learning* dalam mendeteksi berbagai objek sudah banyak diterapkan, namun untuk identifikasi kemiripan bangunan untuk gaya arsitektur masih terbatas. Analisis klasifikasi model desain arsitektur bangunan adat Melayu dapat dilakukan dengan menerapkan metode *Convolutional Neural Network* (CNN). Pendekatan yang digunakan untuk menganalisis klasifikasi dan kemiripan model bangunan adat melayu menggunakan model arsitektur VGG16. Ekstraksi fitur menggunakan model *deep learning* untuk mengidentifikasi jenis bangunan adat Melayu menggunakan parameter atap, jendela, dan ornamen bangunan. Dataset citra bangunan adat Melayu didapatkan dari pengambilan langsung ke lokasi bangunan adat melayu Riau di Kawasan Jalan Muhammad Arifin Pekanbaru Riau untuk *training* sebanyak 644 gambar dan *testing* model sebanyak 106 gambar. Model yang digunakan adalah VGG16. Parameter ukuran kinerja meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Akurasi yang didapatkan dalam penelitian ini adalah 98,77% dari total 106 data yang diuji, sedangkan *precision* 0,8678, *recall* 0,9633, dan *F1-score* 0,9877. Hasil yang didapatkan ini melalui *setting* parameter *learning rate* 0,0001, *drop out* 0,20, dan *epoch* sebesar 25. Secara keseluruhan model VGG16 yang digunakan dalam penelitian ini menghasilkan akurasi yang baik.

**Keywords:** Bangunan Adat Melayu; Convolutional Neural Network; Identifikasi; Optimalisasi; VGG16 Model.



## 1 Pendahuluan

Bangunan adat Melayu memiliki ciri khas yang sangat mencerminkan kekayaan budaya dan sejarah masyarakat Melayu. Desainnya yang unik, dengan elemen-elemen arsitektur seperti atap limas, tiang tinggi, dan ukiran-ukiran tradisional, dengan mengutamakan nilai estetika dan simbolisme yang mencerminkan kebudayaan Melayu yang telah berkembang sejak berabad-abad lalu. Sebagai bagian dari warisan budaya, bangunan adat Melayu memerlukan upaya pelestarian agar identitas budaya ini tetap hidup dalam masyarakat. Namun, tantangan utama dalam pelestarian dan pengenalan bangunan adat Melayu adalah keragaman desain dan bentuk bangunan yang tersebar diberbagai wilayah, yang sering kali membuat proses identifikasi menjadi kompleks dan memerlukan keahlian khusus.

Identifikasi bangunan adat bila dilakukan secara konvensional sangat bergantung pada kepakaran manusia dan dapat memakan waktu yang lama, terutama ketika jumlah bangunan yang harus dianalisis sangat banyak dan tersebar di berbagai daerah. Proses ini juga dapat berisiko mengalami kesalahan, terutama ketika melibatkan perbedaan interpretasi terhadap elemen desain yang sama pada bangunan yang berbeda (Ahdiani et al., 2025);(Alsheikh Mahmoud & Bin Hashim, 2025);(Bashaddadh et al., 2025). Oleh karena otomatisasi sangat diperlukan dalam proses identifikasi bangunan adat Melayu agar lebih efisien dan akurat. Teknologi kecerdasan buatan, khususnya dalam bidang *computer vision* dengan *deep learning*, menawarkan potensi besar untuk meningkatkan kemampuan ini.

*Convolutional Neural Networks* (CNN) adalah salah satu arsitektur pembelajaran mendalam yang sangat efektif dalam pengenalan gambar. CNN memiliki kemampuan untuk mengekstrak fitur visual secara otomatis dari gambar dengan cara yang lebih baik daripada teknik konvensional (S. Li et al., 2022);(Mall et al., 2023). Dalam pengenalan objek dan klasifikasi gambar, CNN menunjukkan kinerja yang sangat efektif dan banyak digunakan dalam berbagai aplikasi, termasuk identifikasi arsitektur dan bangunan tradisional (Jiang et al., 2021). Salah satu arsitektur CNN yang terkenal adalah VGG16, yang banyak digunakan dalam tugas-tugas pengenalan citra karena struktur lapisannya yang sederhana dan kedalamannya yang cukup besar (Fawwaz et al., 2023). VGG16 telah diaplikasikan dalam berbagai studi arsitektur untuk mengenali berbagai jenis

bangunan dengan akurasi yang sangat baik (Fu et al., 2024) (Malhotra & Singh, 2023).

Namun, penggunaan VGG16 dalam identifikasi bangunan adat Melayu menghadapi tantangan tertentu, terutama terkait dengan variasi desain dan kondisi fisik bangunan yang sangat beragam. Beberapa penelitian sebelumnya telah menunjukkan bahwa meskipun VGG16 menunjukkan hasil yang menjanjikan dalam pengenalan gambar, kinerjanya dapat terbatas ketika dihadapkan pada dataset yang lebih kecil atau memiliki variasi yang tinggi dalam fitur gambar, seperti pada bangunan adat Melayu (Shehata & Alaboud, 2025); (Poojary et al., 2021). Oleh karena itu, diperlukan optimasi terhadap model CNN, seperti penggunaan teknik *transfer learning*, *fine-tuning*, dan *data augmentation* untuk meningkatkan kinerja model dalam tugas ini (Janković, 2020);(Abed & Hussain, 2021).

*Transfer learning* bekerja dengan manfaatkan model yang telah dilatih pada himpunan data yang besar, seperti ImageNet, untuk tugas pengenalan bangunan adat Melayu. Menggunakan teknik ini dapat mempersingkat waktu pelatihan dan menaikkan nilai akurasi model untuk dataset yang terbatas (Shorten & Khoshgoftaar, 2019);(Mustafid et al., 2020);(Maulidi et al., 2024). Selain itu, *fine-tuning*, yang melibatkan penyesuaian lapisan-lapisan akhir pada model, dapat dilakukan untuk menyesuaikan model dengan karakteristik visual dari bangunan adat Melayu secara lebih spesifik (Maulidi et al., 2024);(Kevseroglu & Kurban, 2024). Teknik lain yang sangat penting adalah data augmentasi, yang dapat digunakan untuk menambah varians gambar dengan cara memodifikasi dengan teknik rotasi, pemotongan, atau ukuran skala, sehingga model dapat mengenali objek dari berbagai situasi dan kondisi pencahayaan yang berlainan (Zhao et al., 2024);(S. Li et al., 2022).

Berbagai penelitian telah menunjukkan bahwa dengan pendekatan ini, model CNN seperti VGG16 dapat dioptimalkan untuk tugas pengenalan bangunan tradisional dan arsitektur, meskipun terdapat tantangan dalam hal variasi desain (Yoshimura et al., 2019);(H. Li & Dong, 2025);(Lydia & Chandrasekar, 2022). Melalui optimalisasi kinerja model CNN menggunakan teknik-teknik tersebut, diharapkan dapat meningkatkan akurasi dan efisiensi dalam mengidentifikasi bangunan adat Melayu. Dengan demikian, penelitian ini bertujuan untuk



mengeksplorasi dan mengembangkan metode optimalisasi kinerja VGG16 untuk tugas identifikasi bangunan adat Melayu dengan tujuan untuk memfasilitasi pelestarian dan promosi budaya Melayu melalui teknologi.

Upaya pelestarian budaya yang dapat diterapkan pada kawasan *heritage* atau cagar budaya dengan cara dokumentasi digital dengan memberi nilai informasi yang lebih. Tujuannya agar dapat digunakan sebagai pusat pendidikan terkait nilai sejarah dari bangunan tersebut yang meliputi desain arsitektur, sejarah, topografi bangunan, dan fungsi lainnya. Dokumentasi digital cagar budaya arsitektur harus memberikan informasi yang dapat dipercaya sehingga memfasilitasi konservasi, pemeliharaan, dan rehabilitasi. Dokumentasi ini harus dengan setia mencerminkan perubahan yang diderita oleh aset warisan sepanjang sejarah, dengan demikian memungkinkan interpretasi dan studi tentang evolusi dan status bangunan *heritage* saat ini.

Dokumentasi yang lengkap dalam format digital akan bernilai tinggi dan sangat diperlukan dalam mengelola bangunan *heritage* sebelum masuk tahap perencanaan atau perubahan. Keberadaan suatu dokumentasi yang sesuai dengan dunia nyata dapat dilanjutkan ke fase selanjutnya sehingga mempermudah dalam monitoring dan pemeliharaan. Namun keberadaan dokumentasi ini tidak dapat diperoleh dengan mudah sehingga perlu untuk membantu melestarikan dan menyebarluaskan informasi terkait bangunan cagar budaya.

Sebagai upaya wujud pelestarian bangunan *heritage* di Indonesia dapat dilakukan dalam tiga hal, yaitu; adanya administrasi yang berkontribusi tertinggi sebagai sumber daya untuk masalah pelestarian dan pemeliharaan karena memiliki nilai sosiokultural dan dampak ekonomi disekitar barang yang dianggap baik; kedua, pencermatan dampak lingkungan alam yang berpotensi sebagai ancaman terbesar (kerusakan alam, gangguan hewan, perang, bencana alam yang ekstrem, udara yang berpolusi, iklim yang berubah-ubah, kagiatan yang merusak, dan sikap tidak peduli); ketiga, meningkatnya kemajuan teknologi yang mempermudah akses dalam peningkatan kecepatan dan perangkat dalam mengakuisisi gambar yang akurat, adanya alat sensor yang multispektral, dan perangkat pengumpulan data lainnya, serta keberadaan aplikasi canggih yang mendukung dokumentasi digital ini (Jose Llamas, Pedro M. Lerones, Roberto Medina, & García Bermejo, 2017).

Bangunan Adat Melayu dapat dikategorikan sebagai bangunan *heritage* yang menjadi penciri adat tradisional dari Suku Melayu. Melayu adalah anak benua Austronesia yang sudah ada sebelum Islam diperkenalkan. Penduduk Melayu pada saat itu menganut animisme. Islam memiliki pengaruh yang sangat besar dalam kepercayaan masyarakat Melayu. Saat ini, hampir semua orang memahami bahwa Islam adalah Muslim. Masjid dan rumah tinggal adalah contoh arsitektur Melayu yang dapat dilihat keberadannya di wilayah suku Melayu.

Tiga hal yang menjadi ciri khas orang Melayu dalam mendefinisikan identitas: taat ajaran Islam, perayaan terhadap Budaya Melayu, dan penggunaan Bahasa Melayu (Prayogi, A, 2016). Bangunan Adat Melayu memiliki keunikan berupa rumah panggung dengan material utama kayu dengan kearifan lokal yang dapat menyesuaikan dengan lingkungan atau iklim, meminimalkan penggunaan partisi dalam desain, bentuk lantai panggung, menggunakan jendela atau ventilasi dalam jumlah yang banyak, menggunakan material bangunan yang tidak menyerap panas, dan orientasi bangunan menghadap ke barat-timur yang manfaatnya untuk mengurangi sinar matahari langsung (Lim, Jee Yuan, 1987). Tata letak ruang dalam bangunan adat Melayu menggunakan penamaan yang berbeda disesuaikan dengan lokasi daerah dan kebudayaan setempat (Lim, Jee Yuan, 1987). Selain itu ciri unik lainnya dari bangunan Adat Melayu dapat dilihat dari bentuk atap, tampak rumah terhadap jalan raya, langgap, dan struktur atap (Mohamad Rashidi Pakri & Nurul Farhana Low Abdullah, 2013); (G. Faisal & Y. Firzal, 2020).

Upaya pelestarian bangunan Adat Melayu sebagai salah satu bangunan *heritage* perlu melakukan identifikasi bangunan Adat Melayu. Jenis bangunan Adat Melayu sangat beraneka ragam, yaitu bangunan Adat Melayu Riau, Bangunan Adat Melayu Kalimantan, dan bangunan Adat Melayu Sumatera Utara. Ketiga daerah tersebut memiliki ciri khas yang berbeda berdasarkan kategori bentuk atap, ornamen, tiang, dan struktur atap. Sekilas mata jika dilihat bangunan adat Melayu hampir sama, namun bila dilihat dari bentuk fisik dan struktur ruang terdapat perbedaan. Perlu melakukan dokumentasi digital untuk mengidentifikasi jenis bangunan adat Melayu Riau, Melayu Kalimantan, dan Melayu Sumatera Utara. Hal ini dibutuhkan sebagai referensi bagi arsitek budaya ketika melakukan redesain untuk pengaturan tata kota. Dalam konsep



*heritage*, bangunan tidak boleh diubah bentuknya namun secara fungsi boleh dilakukan perubahan. Hal ini diatur dalam Peraturan Pemerintah Nomor 1 Tahun 2022 terkait Register dan Pelestarian Cagar Budaya.

Permasalahan yang terjadi adalah adanya perbedaan persepsi hasil desain dengan kondisi nyata. Konsep bangunan adat yang telah didesain dengan kondisi riil Rumah Kampung yang ada memang berbeda. Perlu dilakukan analisis klasifikasi model desain arsitektur bangunan Rumah Kampung ini dengan kondisi nyata dan kesesuaian filosofi kesejarahan bangunan tersebut. Pendekatan yang digunakan untuk menganalisis klasifikasi dan kemiripan model bangunan dengan kondisi nyata adalah pendekatan analisis *Computer Vision* khususnya *Machine Learning* (ML) yang dapat membantu masyarakat dan arsitek untuk mengambil keputusan yang tepat (Winiarti, Yulianto, & Sunardi, 2021).

Identifikasi bangunan adat Melayu yang tersebar di berbagai wilayah sering kali menjadi tantangan besar karena keragaman desain arsitektur, kondisi fisik yang bervariasi, dan keterbatasan jumlah dataset yang representatif. Meskipun pengenalan bangunan tradisional dapat dilakukan secara manual oleh ahli arsitektur, proses ini sangat memakan waktu, rentan terhadap kesalahan subjektif, dan tidak efisien ketika harus menangani jumlah bangunan yang besar. Berdasarkan kondisi ini diperlukan suatu teknologi sebagai suatu solusi secara otomatis dalam mengidentifikasi bangunan adat Melayu yang akurasi dan dengan waktu singkat.

*Convolutional Neural Networks* (CNN) merupakan metode pembelajaran mendalam yang banyak dipakai dalam pengolahan citra dan telah terbukti efektif dalam berbagai aplikasi pengenalan objek, termasuk bangunan tradisional. Namun, penerapan CNN, khususnya arsitektur VGG16, untuk identifikasi bangunan adat Melayu masih menghadapi beberapa masalah, seperti variasi besar dalam desain, kondisi pencahayaan yang berbeda, serta keterbatasan jumlah data yang tersedia. Hal ini mengarah pada penurunan kinerja model, terutama dalam hal akurasi dan generalisasi.

Fokus masalah dalam penelitian ini adalah mengoptimalkan kinerja VGG16 untuk tugas identifikasi bangunan adat Melayu dengan meningkatkan akurasi klasifikasi dan mengatasi tantangan seperti *overfitting*, variasi dalam data, dan terbatasnya *dataset*. Penelitian ini bertujuan menerapkan teknik-teknik seperti *transfer*

*learning*, *fine-tuning*, augmentasi data, dan regularisasi untuk meningkatkan performa VGG16 dalam studi ini.

Melatih model dilakukan dengan menggunakan *dataset* berupa gambar bangunan melayu yang telah diberi label. Identifikasi gambar dengan pembelajaran mendalam mengoptimalkan potensi pengetahuan tersembunyi dari kumpulan sampel data yang terstruktur dan tidak terstruktur. Teknik ML yang populer adalah Pembelajaran Mendalam (PM) pada sebuah model dengan banyak lapisan tersembunyi. Pembelajaran Mendalam (PM) merupakan bagian dari ML yang kini mendominasi bidang sistem cerdas karena kinerjanya yang baik (Krizhevsky, A, Sutskever, I, & Hinton, G. E, 2012). Model PM dapat dikelompokkan menjadi tiga model, yaitu generatif, diskriminatif, dan *hybrid*. Salah satu contoh model diskriminan adalah *Deep Neural Network* (DNN), *Convolutional Neural Network* (CNN), dan *Recurrent Neural Network* (RNN).

Salah satu model generatif termasuk *Deep Neural Network* (DNN), mesin Boltzman yang dibatasi, dll (Fernandes Junior & Yen, G. G, 2019). Penerapan CNN dapat ditemukan pada klasifikasi citra. Dengan kinerja yang tinggi dalam klasifikasi gambar Model CNN dapat digunakan dengan teknik *Transfer Learning* (TL). Teknik TL menggunakan model pra-terlatih untuk melatih model baru. Hasil pelatihan berupa pengetahuan model yang relevan digunakan untuk mencari solusi. Karakteristik yang dipelajari dengan prapelatihan pada dataset dapat ditransfer ke jaringan model yang telah dibuat.

TL mempersingkat waktu pembuatan dan pelatihan model CNN (Rizki, A. M & Marina, N, 2019). Beberapa percobaan telah dilakukan dengan memperbaiki klasifikasi gambar, diantaranya dengan menggunakan CNN sebagai jenis jaringan saraf *multi-layer* khusus yang terinspirasi oleh mekanisme susunan optik makhluk hidup. Penelitian yang dilakukan oleh Hubel dan Wiesel menemukan sel kortikal pada hewan yang dapat mendeteksi cahaya pada bidang penerimaan yang sempit. Pada tahun 1980, seorang peneliti Jepang bernama Fukushima memperkenalkan *neocognitron* yang merupakan jaringan berlapis yang dapat mengidentifikasi pola visual hirarkis melalui pembelajaran. Dari sinilai Model CNN dikenal sebagai jaringan yang dianggap awal inspirasi teoretis CNN(Su et al., 2011).

Pada masalah klasifikasi dan pengenalan citra etode CNN telah banyak dimanfaatkan.



Penelitian yang telah dilakukan pada tahun 2020 mengidentifikasi bangunan *heritage* menggunakan metode CNN yang dapat mengelompokkan bangunan jenis berdasarkan fitur ornamen sebagai indikator yang dipakai dalam mengidentifikasi objek, yaitu Bangunan Eropa, Bangunan jawa, Bangunan China, dan Bangunan Islam (Winiarti, Yulianto, & Sunardi, 2021), (Pramono, Winiarti, Satwiko, & Yanti, 2023). Penelitian ini dapat mengidentifikasi bangunan tradisional Jawa ke dalam lima kelas, yaitu Rumah Limasan, Rumah Joglo, Rumah Kampung, Rumah Panggang Pe, dan Rumah Tajug (Winiarti et al., 2022). Penelitian lain terkait *machine learning* telah dilakukan dalam beberapa kasus, seperti dalam klasifikasi jenis buku dengan menggunakan CNN (Winiarti, W. Cendani, U. Ahdiani, & T. Ismail, 2022). CNN terdapat koneksi dan parameter yang lebih sedikit dibandingkan dengan metode *Convolutional Neural Network-Based Deep Learning*.

Dengan menggunakan ukuran standar dan jaringan yang sama, membuat pelatihan model menjadi lebih sederhana dan mudah. Saat ini tersedia dataset berukuran besar yang dapat digunakan untuk penelitian dengan metode CNN (Maxwell, A.E, Warner, T.A, & Guillen,L.A, 2021) (Nurkhasanah & Murinto, 2021). Kumpulan data ini termasuk ImageNet (Wu, Z, et al., 2019), AlexNet (Hubel, David H, & Torsten N. Wiesel, 1964), Kaggle (Kaggle, 2019), MNIST (Kadam, S. S, Adamuthe, A. C, & Patil, A. B, 2020), CIFAR-10 (Wang, C & Xi, Y, 2015). Dalam mengetahui kinerja model dilakukan dengan uji akurasi model menggunakan matriks konfusi (Xiaoyu Yu & Youngah Do, 2024).

Penelitian ini memiliki signifikansi yang besar dalam bidang pelestarian budaya dan pengembangan teknologi kecerdasan buatan, khususnya dalam pengenalan citra. Identifikasi bangunan adat Melayu merupakan langkah penting dalam melestarikan warisan budaya yang kaya, yang mencerminkan tradisi, sejarah, dan nilai-nilai masyarakat Melayu. Namun, dengan jumlah bangunan yang sangat banyak dan beragam desainnya, pengenalan dan pelestarian bangunan ini secara manual menjadi tantangan besar, baik dari segi waktu, tenaga, maupun ketepatan. Penelitian ini menawarkan solusi teknologi yang efisien dan akurat dalam mengidentifikasi bangunan adat Melayu, dengan tujuan untuk mendukung

pelestarian dan promosi budaya Melayu di era digital.

Secara spesifik, penelitian ini memberikan kontribusi pada pengembangan aplikasi *deep learning* dalam pengenalan bangunan adat, yang dapat digunakan oleh lembaga pelestarian budaya, pemerintah, maupun akademisi untuk memetakan dan mendokumentasikan bangunan adat Melayu dengan lebih mudah dan cepat. Penerapan arsitektur CNN seperti VGG16 dalam konteks ini bertujuan untuk memberikan kemampuan untuk mengotomatiskan proses deteksi dengan tingkat akurasi yang lebih baik dibandingkan dengan cara manual. Optimasi kinerja model CNN melalui teknik seperti TL, *fine-tuning*, dan augmentasi data dapat meningkatkan kemampuan model dalam mengenali berbagai variasi desain bangunan, meskipun dataset yang tersedia terbatas.

Penelitian ini berkontribusi dalam bidang *computer vision* sebagai wujud pengembangan teknologi, yang dapat diperluas untuk aplikasi pengenalan objek lainnya di bidang arsitektur, konservasi, dan bahkan bidang industri lainnya, seperti sektor properti dan perkotaan. Dengan meningkatkan akurasi dan efisiensi model CNN dalam mengidentifikasi bangunan adat, penelitian ini berpotensi membuka jalan bagi aplikasi yang lebih luas dalam preservasi dan analisis arsitektur tradisional di seluruh dunia.

Dengan demikian, hasil dari penelitian ini tidak hanya berperan dalam bidang pelestarian budaya Melayu, tetapi juga memberikan dampak besar bagi pengembangan teknologi AI dalam pengolahan citra dan penerapannya pada berbagai sektor lain, termasuk pendidikan, penelitian arsitektur, dan pelestarian warisan budaya global.

## 2 Metodologi

Penelitian ini akan menggunakan desain penelitian eksperimen dengan pendekatan kuantitatif untuk mengukur kinerja model VGG16 dalam mengklasifikasikan bangunan adat Melayu.



2.1 Metodologi Penelitian, tahapan yang dapat dilakukan sebagai berikut:

a. Pengumpulan Data:

*Dataset*: menggunakan dataset yang terdiri dari gambar bangunan adat Melayu dari daerah Riau dan Kalimantan dengan pengambilan secara langsung. *Dataset* ini akan mencakup berbagai jenis bangunan tradisional Melayu, seperti rumah adat, masjid, dan istana. Gambar-gambar tersebut akan mencakup variasi pencahayaan, sudut pandang, dan latar belakang untuk memastikan model terpapar pada kondisi yang beragam. Pengambilan citra bangunan tradisional melayu secara langsung menggunakan alat kamera yang kemudian dikumpulkan dalam satu *dataset* yang bernama Bangunan Melayu. *Dataset* Bangunan Melayu terdiri dari 649 citra yang dibagi menjadi 433 citra *training*, 108 citra validasi, dan 108 citra *testing*. *Dataset* tersebut dibagi menjadi tiga kategori, yaitu atap, pilar, dan jendela.

Pelabelan Data: Setiap gambar akan diberi label sesuai dengan jenis bangunan ke dalam 3 kelas: bangunan Melayu Riau, Bangunan Kalimantan, dan Non Melayu.

Tujuan pengumpulan data adalah untuk mengumpulkan gambar bangunan adat Melayu dari berbagai daerah (Riau dan Kalimantan). Dataset yang dikumpulkan mencakup berbagai jenis bangunan dan situasi untuk memastikan model dapat mengenali berbagai variasi bangunan. Data ini kemudian dilabeli agar model bisa belajar membedakan jenis bangunan berdasarkan kategori yang telah ditentukan, seperti atap, pilar, dan jendela.

b. Pra-pemrosesan Data:

Pengubahan ukuran gambar: Semua gambar akan diubah ukurannya menjadi ukuran konsisten untuk mencocokkan ukuran gambar yang diperlukan VGG16.

Normalisasi: dilakukan normalisasi terhadap nilai piksel dengan rentang data [0, 1] untuk memastikan konvergensi yang lebih cepat selama pelatihan. *Pre-processing* dilakukan dengan melakukan *de-noising* dan *sampling* citra menjadi ukuran 256 x 256 piksel. Sampel citra Bangunan Melayu berupa bentuk atap, pilar, dan jendela. Tahapan pembuatan model dimulai dari *processing* data, membuat arsitektur model, *training* dan *testing*, dan evaluasi untuk mengetahui performa dari model VGG16 dalam mendeteksi Bangunan Adat Melayu.

Augmentasi Data: Teknik augmentasi gambar, seperti rotasi, pembalikan, pemotongan, dan perubahan skala, akan diterapkan untuk memperbesar dataset secara artifisial, meningkatkan kemampuan model untuk mengenali berbagai kondisi gambar.

Tujuan dari preprosesing data ini untuk mempersiapkan gambar agar bisa digunakan oleh model dengan maksimal. Gambar diubah ukurannya agar seragam dan nilai warnanya dinormalisasi agar model bisa belajar lebih cepat dan akurat. Teknik seperti *augmentasi data* digunakan untuk memperbesar dataset secara artifisial, yang bertujuan agar model lebih tahan terhadap berbagai variasi gambar saat melakukan klasifikasi.

c. Arsitektur Model:

Model Dasar VGG16: menjadikan Model VGG16 yang sudah dilatih pada dataset ImageNet sebagai model dasar. Bobot yang sudah dilatih pada ImageNet akan digunakan untuk *transfer learning*.

*Fine-Tuning*: Mengganti lapisan dense yang disesuaikan untuk tugas klasifikasi bangunan adat Melayu dibeberapa lapisan terakhir dari model VGG16

Regularisasi: Lapisan *dropout* dan regularisasi L2 akan ditambahkan pada model untuk mencegah *overfitting*, mengingat ukuran dataset yang relatif kecil.

Tujuan dari membuat arsitektur model adalah untuk memilih model yang sudah terbukti kuat, yaitu VGG16, dan memodifikasinya agar dapat mengenali bangunan adat Melayu. *Fine-tuning* atau penyesuaian dilakukan pada lapisan akhir model untuk memastikan model lebih cocok dengan tugas ini. Regularisasi ditambahkan untuk menghindari model dari kesalahan atau *overfitting* saat belajar dari dataset kecil.

d. Pelatihan Model:

Pembagian Data Latih/Uji: membagi dataset menjadi data latih dan data uji dengan komposisi 80:20. Data latih digunakan untuk melatih model, sementara data uji digunakan untuk mengevaluasi kinerja model.

Algoritma Optimasi: Melatih Model dengan menggunakan algoritma Adam dengan laju pembelajaran yang sesuai. Fungsi kerugian *cross-entropy* akan digunakan untuk tugas klasifikasi.

Metrik Evaluasi: Kinerja model akan dievaluasi menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score* untuk menilai kemampuan klasifikasi model(Devi Yunita & Maulana Fansyuri, 2025).



Pada bagian ini, model akan dilatih menggunakan data yang telah dibagi menjadi dua bagian: data untuk latihan dan data untuk uji. Tujuan utamanya adalah untuk mengajarkan model mengenali gambar dengan benar. Teknik optimasi dan metrik evaluasi seperti akurasi digunakan untuk menilai kinerja model. Hasil evaluasi ini akan membantu memastikan model dapat mengidentifikasi bangunan adat Melayu dengan tepat.

e. Penyempurnaan Hyperparameter:

Pencarian Grid/Acak: melakukan penyesuaian seperti laju pembelajaran, ukuran batch, dan jumlah epoch akan dioptimalkan menggunakan pencarian grid atau pencarian acak.

*Early Stopping*: menerapkan teknik *early stopping* untuk menghentikan pelatihan saat model bekerja tidak lagi dapat meningkatkan validasi data, sehingga mencegah *overfitting*.

Bagian ini bertujuan untuk memperbaiki pengaturan teknis model seperti laju pembelajaran, ukuran batch, dan jumlah epoch agar model dapat belajar dengan lebih efisien. Dengan menggunakan teknik pencarian dan *early stopping*, model dapat dihentikan lebih cepat jika tidak ada perbaikan lebih lanjut, sehingga menghindari pemborosan waktu dan sumber daya.

f. Analisis Data

Kinerja model VGG16 akan dianalisis melalui serangkaian uji statistik untuk membandingkan akurasi dan metrik kinerja lainnya sebelum dan setelah teknik optimasi (seperti transfer learning, fine-tuning, dan data augmentation) diterapkan. Selain itu, perbandingan antara VGG16 dan arsitektur CNN lainnya akan dilakukan untuk menentukan model terbaik dalam mengidentifikasi bangunan adat Melayu.

Pada bagian ini, kinerja model akan dianalisis dengan menggunakan berbagai uji statistik untuk memastikan apakah model sudah cukup baik dalam mengenali bangunan adat Melayu setelah penerapan berbagai teknik. Hasil

dari analisis ini juga akan dibandingkan dengan model lain untuk melihat mana yang paling efektif dalam tugas ini.

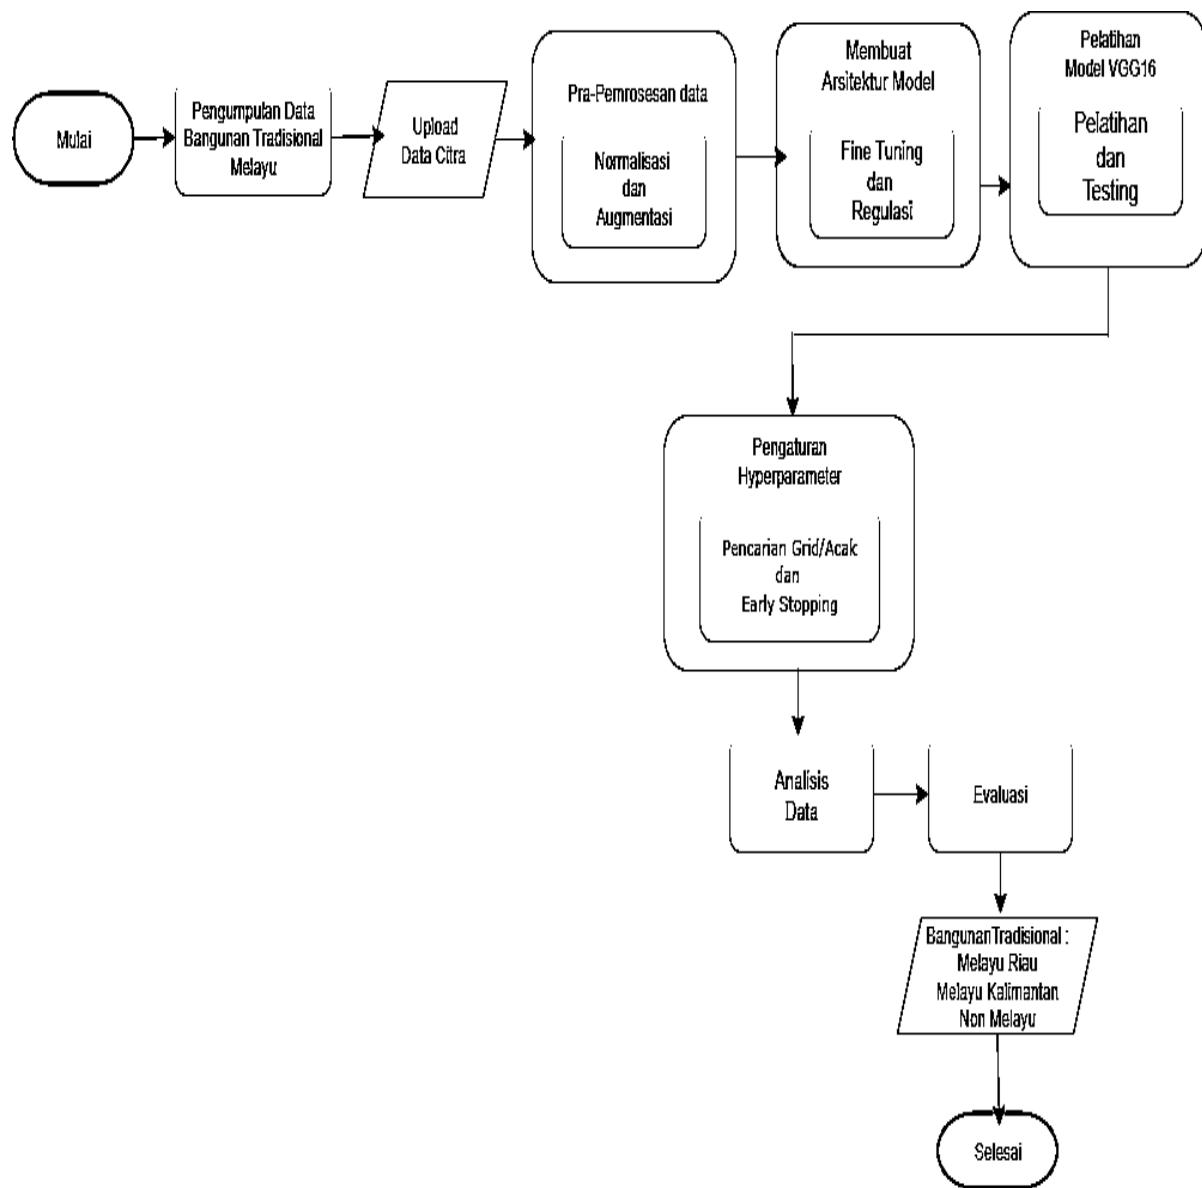
Diharapkan bahwa model VGG16, setelah dioptimalkan menggunakan transfer learning, fine-tuning, data augmentation, dan regularisasi, akan mengungguli model yang tidak dioptimalkan dan mencapai akurasi klasifikasi yang lebih tinggi untuk bangunan adat Melayu. Kontribusi besar dari penelitian ini diharapkan dapat mengidentifikasi dan klasifikasi bangunan adat Melayu sebagai upaya pelestarian budaya. Penelitian ini juga akan memberikan kontribusi pada pengembangan aplikasi *deep learning* di bidang arsitektur dan konservasi warisan budaya, membuka jalan untuk metode yang lebih akurat dan skalabel dalam melestarikan warisan budaya melalui teknologi.

## 2.2 Deskripsi Penelitian

Inisialisasi citra Bangunan Adat Melayu sebagai input dikumpulkan dan diklasifikasikan dalam beberapa kategori. Ada tiga parameter yang dipakai dalam penelitian ini, yaitu atap, jendela, dan pilar. *Pre-processing* data meliputi *resize*, *scaling*, dan augmentasi citra. Metode augmentasi dimaksudkan agar sampel citra baru dihasilkan dari citra yang ada untuk meningkatkan dan menyiapkan dataset.

Data yang telah dikoleksi sebanyak 750 kemudian dikelompokkan menjadi dua, yaitu data latih (644 gambar) dan data uji (106 gambar) dari jumlah total *dataset* yang diperoleh. Setelah *dataset* tervalidasi akan dilakukan pembuatan model arsitektur CNN dengan VGG16 dan kemudian dilakukan pelatihan dan pengujian. Jika kinerja model arsitektur belum memberikan hasil baik maka dilakukan perbaikan data. Evaluasi dilakukan menggunakan beberapa tahap, setelah itu dilakukan pelatihan VGG16 Model. Gambar 1 menunjukkan tahapan penelitian yang dilakukan untuk identifikasi bangunan adat Melayu.





Gambar 1. Diagram alir penelitian

Gambar 1. Diagram alir penelitian

### 3 Pembahasan

#### 3.1 Convolutional Neural Network

CNN merupakan komponen dari *Deep Learning* (DL) yang dapat digunakan untuk mengenali serta mendeteksi objek dalam gambar digital. CNN adalah tipe jaringan syaraf buatan yang dirancang secara khusus agar mampu mengolah data dalam bentuk matriks. CNN digunakan untuk mengelompokkan data yang sudah memiliki label dengan metode pembelajaran terawasi. Secara umum, CNN digunakan untuk mengidentifikasi dan mendeteksi objek. Struktur

jaringan CNN terdiri dari beberapa elemen yang akan dibahas berikut ini.

##### 3.1.1 Convolution layer

Bagian penting dari cara membangun CNN adalah lapisan konvolusional. Pada bagian ini, hasil dari lapisan sebelumnya diubah melalui suatu proses. Lapisan ini berfungsi sebagai langkah dasar dalam cara kerja CNN. Pemasangan lapisan konvolusional sangatlah penting. Konvolusi adalah istilah matematika untuk penggunaan berulang dari keluaran suatu fungsi sebagai masukan untuk

fungsi lainnya. Proses konvolusi menggunakan dua fungsi yang memiliki argumen dengan nilai riil. Hal ini menghasilkan fungsi yang berfungsi sebagai peta fitur dari gambar yang masuk. Hal-hal yang masuk dan keluar dapat dianggap sebagai dua argumen dengan nilai riil.

Konvolusi adalah konsep matematika yang, ketika membahas penanganan gambar, berarti menggunakan pola yang telah ditentukan pada setiap titik dalam gambar. Tujuan penggunaan konvolusi pada data gambar adalah untuk menarik keluar bagian-bagian penting dari gambar yang dimasukkan. Konvolusi membuat perubahan langsung pada data yang masuk, yang sesuai dengan cara informasi tersebut disusun di dalam data. Jumlah dalam lapisan menentukan pola yang akan digunakan, sehingga pola konvolusi dapat dipelajari menggunakan data yang masuk ke CNN.

### 3.1.2 Pooling layer

Lapisan *pooling* adalah jenis lapisan yang mengambil peta fitur sebagai input, lalu mengolah input tersebut menggunakan berbagai tindakan berbasis matematika yang bergantung pada nilai piksel. Dalam model CNN, lapisan *pooling* ditempatkan pada ruang-ruang yang telah ditentukan, biasanya setelah beberapa lapisan konvolusi telah dibuat. Lapisan *pooling* dapat ditempatkan bersama lapisan-lapisan konvolusi, satu demi satu, sesuai dengan cara model CNN dibangun. Tugas lapisan *pooling* adalah secara perlahan memperkecil ukuran total ruang output dalam peta fitur; hal ini membantu mengurangi jumlah hal yang perlu dipertimbangkan dan beban kerja jaringan, yang juga membantu mengendalikan *overfitting*. Lapisan *pooling* digunakan untuk mengurangi perubahan, mempermudah perhitungan, dan mendapatkan detail penting dari area di sekitarnya. Ada dua jenis lapisan *pooling*: *Max pooling* dan *Average pooling*. *Max pooling* membantu menarik detail terpenting, dan *Average pooling* membuat proses lebih halus daripada *Max pooling*. Lapisan *pooling* digunakan untuk mendapatkan angka *pooling* terbesar atau angka *pooling* rata-rata dari bagian-bagian gambar. *Max pooling* adalah metode *pooling* yang sering digunakan dalam CNN. *Max pooling* mendapatkan hasil dari lapisan yang menemukan fitur dan membaginya ke dalam kotak-kotak yang lebih kecil, kemudian mengambil angka terbesar dari setiap kotak untuk membuat matriks gambar yang lebih kecil.

### 3.1.3 Fungsi aktivasi ReLU

Unit Linear Tersearahkan (ReLU) adalah hal pertama yang menunjukkan bagaimana jaringan saraf dapat menangani hal-hal yang rumit. Fungsi ini ditunjukkan sebagai  $(0, x)$ . ReLU membantu membuat hal-hal menjadi lebih kompleks dan membuat model menampilkannya dengan lebih baik.

Fungsi aktivasi ReLU ditunjukkan sebagai  $f(x) = \max(0, x)$ . Output neuron akan bernilai 0 jika inputnya negatif. Jika inputnya positif, maka output neuron adalah jumlah input yang diterimanya.

### 3.1.4 Fully-Connected Layer

Lapisan Terhubung Penuh (Fully-Connected) adalah lapisan di mana setiap neuron di lapisan sebelumnya terhubung sepenuhnya dengan neuron dilapisan berikutnya, seperti cara jaringan saraf tiruan biasa diatur. Pada dasarnya, lapisan ini sering digunakan dalam *Multy Layer Perceptron* (MLP), yang mencoba mengubah ukuran data agar dapat dikelompokkan dalam garis lurus.

Perbedaan utama antara lapisan Terhubung Penuh dan lapisan konvolisional biasa adalah neuron dilapisan konvolisional hanya terhubung ke bagian tertentu dari input, sementara dilapisan Terhubung Penuh, neuron-neuron terhubung sepenuhnya. Meskipun demikian, kedua jenis lapisan ini masih melakukan perhitungan *perkalian titik* (*dot product*), sehingga fungsinya tidak berbeda.

### 3.1.5 Fungsi Aktivasi Softmax

Aktivasi *softmax* digunakan untuk mendapatkan keluaran klasifikasi. Fungsi ini memberikan angka-angka yang dapat kita anggap sebagai probabilitas yang belum sepenuhnya siap untuk setiap kategori. Secara formal, fungsi softmax standar  $\theta = \sigma: R^k \rightarrow (0,1)^k$  di mana  $k > 1$  dengan mengambil vector  $\mathbf{z} = (z_1, \dots z_k) \in R^k$  dan menghitung setiap komponen vector  $\sigma(\mathbf{z}) = \epsilon(0,1)^k$ , sehingga fungsi *softmax* ditunjukkan dalam Persamaan (1) (Raghuram S, Anirudh S Bharadwaj, Deepika S K, Mridula S Khadabadi, & Aditya Jayaprakash, 2022).

$$\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (1)$$

Dengan kata lain, fungsi softmax mengambil eksponensial reguler dari setiap bagian  $\sigma(z)_i$  dari vektor  $\mathbf{z}$ , yang memiliki nilai dari 0 hingga 1,



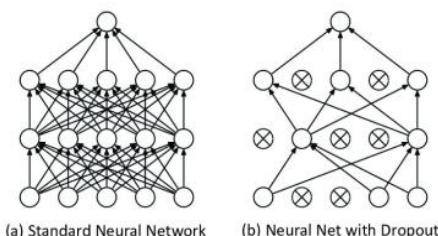
dengan  $k$  sebagai bilangan riil, dan menyesuaikan nilai-nilai ini dengan membaginya dengan jumlah semua eksponensial. Langkah normalisasi ini memastikan bahwa jumlah semua bagian dalam vektor keluaran  $\sigma(z)$  sama dengan 1. Nama softmax berasal dari bagaimana eksponensial meningkatkan setiap nilai terbesar dalam vektor masukan. Misalnya, *softmax* dari (1,2,8) menghasilkan (0,001, 0,002, 0,997), menunjukkan bahwa hampir semua bobot satuan total dalam hasil menuju ke nilai elemen tertinggi dalam vektor, yaitu 8. Nilai  $z$  adalah vektor yang terdiri dari nilai-nilai yang dihasilkan oleh lapisan terhubung penuh terakhir.

Lapisan penggabungan membantu memperkecil bagian-bagian yang menyerupai gambar dan mengurangi jumlah hal yang perlu diukur, sehingga mencegah model terlalu akurat dalam menyesuaikan data pelatihan. Lapisan putus sekolah menambahkan cara untuk menonaktifkan atau mempertahankan sel-sel saraf berdasarkan angka peluang "p" yang berada di antara 0 dan 1. Lapisan putus sekolah sangat membantu dalam membedakan berbagai jenis hal.

### 3.1.6 Dropout Regularization

Regularisasi *Dropout* adalah metode yang digunakan dalam jaringan saraf tiruan untuk menghentikan beberapa neuron agar tidak berfungsi saat melatih model. Neuron yang dinonaktifkan seperti neuron yang dihapus secara acak. Ini berarti neuron yang dinonaktifkan tidak akan berfungsi untuk sementara waktu, dan jaringan serta penyesuaian baru tidak akan digunakan untuk memperbaiki kesalahan.

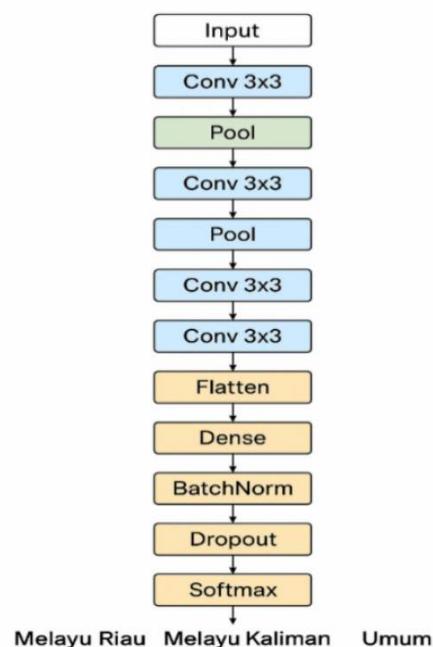
Gambar 3 menunjukkan cara kerja regulasi dropout. Jaringan saraf tiruan pada bagian (a) adalah jaringan saraf tiruan normal dengan dua bagian tersembunyi. Namun pada bagian (b), jaringan saraf tiruan menggunakan dropout. Anda dapat melihat bahwa beberapa neuron aktivasi tidak dapat digunakan lagi. Metode ini sangat mudah ditambahkan ke model CNN dan akan membantu model bekerja lebih baik saat pelatihan serta mengurangi kemungkinan *overfitting*.



Gambar 2. *Dropout Regulation*

### 3.2 Model VGG16

VGG16 merupakan jenis CNN yang dianggap sebagai salah satu model *computer vision* terbaik sampai saat ini (Ravi Raj Choudhary, Salvi Paliwal, & Gaurav Meena, 2023). VGG16 merupakan *pretrained model* yang digunakan untuk meningkatkan kinerja dan klasifikasi rumah tradisional. VGG16 merupakan salah satu algoritma untuk klasifikasi citra dan mudah untuk digunakan dengan *transfer learning*.



Gambar 3. Arsitektur Model CNN VGG16

Pada analisis dan deteksi kualitas dari citra Bangunan Adat Melayu, inisial model transfer informasi didapatkan dari *pre-trained* model VGG16. Model VGG mempunyai ukuran filter kernel yang besar, terdiri 11 dan 5 *layer convolution* dengan ukuran kernel filter 3x3. Ukuran citra input adalah 224 x 224 seperti yang diperlihatkan dalam Gambar 3.

Visualisasi dari Gambar 3 menampilkan arsitektur model berbasis VGG16 yang digunakan untuk klasifikasi bangunan tradisional Melayu menjadi tiga kelas, yaitu Melayu Riau, Melayu Kalimantan, dan Umum. Alur dimulai dari lapisan input, kemudian melewati beberapa lapisan konvolusi (Conv 3x3) yang diikuti dengan pooling untuk ekstraksi fitur, dilanjutkan dengan flattening untuk mengubah fitur spasial menjadi vektor. Setelah itu, arsitektur memasukkan lapisan *Dense*, *Batch Normalization*, dan *Dropout* sebagai



regulasi, sebelum menuju ke lapisan Softmax yang menghasilkan probabilitas untuk ketiga kelas tersebut.

Dengan struktur arsitektur VGG16 dalam python sebagai berikut:

Script: vgg16\_melayu\_classifier.py  
Deskripsi: Transfer learning dengan VGG16 untuk klasifikasi 3 kelas:  
- melayu\_riau  
- melayu\_kalimantan  
- umum (bangunan umum/non-Melayu)

Catatan struktur dataset (direkomendasikan):

root\_dataset/  
|--- train/  
| |--- melayu\_riau/  
| |--- melayu\_kalimantan/  
| |--- umum/  
|--- val/ # (opsional; kalau tidak ada, gunakan validation\_split)  
| |--- melayu\_riau/  
| |--- melayu\_kalimantan/  
| |--- umum/

|--- test/ # (opsional untuk evaluasi akhir)  
|--- melayu\_riau/  
|--- melayu\_kalimantan/  
|--- umum/

Format tersebut menunjukkan bagaimana pembagian dataset disimpan dalam suatu folder yang digunakan untuk split data training dan validasi. Hal ini diperlukan untuk membagi data untuk pelatihan dan validasi yang akan menggunakan pembagian data 80:20.

### 3.3 Evaluasi dengan Matrik Konfusi

Akurasi ditemukan dengan menghitung jumlah positif aktual yang benar (TP), negatif aktual yang benar (TN), positif yang salah (FP), dan negatif yang salah (FN) menggunakan jenis dan hasil prediksi yang dihasilkan oleh model VGG16. Persamaan (2), (3), dan (4) digunakan untuk menghitung akurasi, presisi, dan *recall* model. Tabel 1 menunjukkan hasil pengujian menggunakan berbagai opsi pengaturan.

Tabel 1 Hasil Percobaan dengan variasi parameter

No.	Epoch	Learning Rate	Dropout Rate	Training Loss	Validation Loss	Validation Accuracy
1	25	0,00100	0,20	0,0076	0,0213	0,9877
2	25	0,00010	0,20	0,1552	0,1822	0,9537
3	25	0,00001	0,20	0,1088	0,1842	0,9792
4	30	0,00100	0,25	0,0156	0,0163	0,9877
5	30	0,00010	0,25	0,1275	0,2203	0,9723
6	30	0,00001	0,25	0,6293	0,7054	0,8245
7	20	0,00100	0,20	0,0173	0,1041	0,9877
8	20	0,00010	0,25	0,1833	0,2512	0,9607
9	20	0,00001	0,30	0,7695	0,8237	0,6813
10	25	0,00100	0,25	0,0128	0,0485	0,9877
11	25	0,00010	0,30	0,1608	0,2038	0,9630
12	25	0,00001	0,35	0,7685	0,7632	0,7067

$$\text{akurasi} = \frac{TP+TN}{(TP+TN+FP+FN)} \quad (2)$$

$$\text{Recall} = \frac{TP}{(TP+FN)} \quad (4)$$

$$\text{presisi} = \frac{TP}{(TP+FP)} \quad (3)$$

Tabel 1 menunjukkan pengaruh variasi parameter *epoch*, *learning rate*, dan *dropout rate* terhadap performa model VGG16 dalam mengklasifikasikan bangunan tradisional Melayu menjadi tiga kelas.

1. Pengaruh *Learning Rate* (LR)
  - o *Learning rate* 0,001 konsisten menghasilkan kinerja terbaik dengan

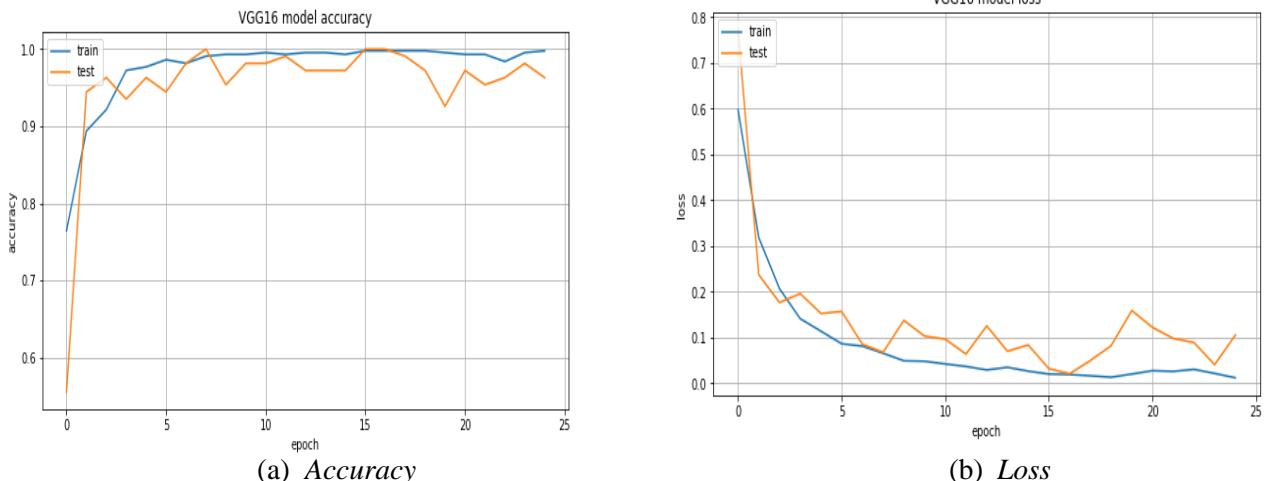
akurasi valid mencapai 98,77% pada beberapa konfigurasi (Percobaan 1, 4, 7, dan 10).

- o *Learning rate* 0,0001 masih memberikan hasil cukup baik (95–97%), tetapi cenderung menghasilkan validation loss yang lebih tinggi dibandingkan LR 0,001.
- o *Learning rate* 0,00001 menunjukkan hasil yang sangat buruk (validation



- accuracy hanya 68–82%) dengan validation loss tinggi, menandakan model sulit belajar (underfitting).
2. Pengaruh *Dropout Rate*
    - o *Dropout* 0,20–0,25 memberikan hasil optimal dengan akurasi tinggi dan validation loss rendah (misalnya Percobaan 1, 4, dan 10).
    - o *Dropout*  $\geq 0,30$  menurunkan performa secara signifikan (Percobaan 9 dan 12), karena terlalu banyak neuron yang dimatikan sehingga menghambat pembelajaran.
  3. Pengaruh Jumlah *Epoch*
    - o *Epoch* 25–30 lebih stabil dibanding epoch 20. Misalnya, Percobaan 1 (25 epoch, 0,001, dropout 0,20) menghasilkan validation accuracy 98,77% dengan loss rendah.
    - o *Epoch* 20 tetap bisa mencapai akurasi tinggi (Percobaan 7 = 98,77%), namun validation loss lebih tinggi (0,1041), sehingga model berpotensi kurang stabil dibanding *epoch* yang lebih banyak.
4. Kombinasi Optimal
  - o Kombinasi  $LR = 0,001$ , *Dropout* = 0,20–0,25, dan *Epoch* 25–30 adalah yang paling optimal, karena mampu menjaga keseimbangan antara *training loss* rendah, validation loss rendah, dan validation accuracy tinggi (mendekati 99%).
5. Kombinasi Tidak Optimal
  - o  $LR$  terlalu kecil (0,00001) atau *dropout* terlalu tinggi ( $\geq 0,30$ ) mengakibatkan over-regularisasi, sehingga akurasi validasi menurun drastis.
  - o Hal ini menunjukkan pentingnya memilih *learning rate* yang tepat dan *dropout* moderat agar model tidak underfitting maupun overfitting.

Gambar 5 memperlihatkan kinerja model yang diukur dan diverifikasi dengan *training*, *testing*, dan validasi untuk citra Bangunan Adat Melayu. Matrik konfusi terbaik sebesar 98,77% didapat dari beberapa *setting* dengan *learning rate* 0,0001, *epoch* sebesar 25, dan *dropout* 0,20.



Gambar 4. *Accuracy* dan *Loss*

### 3.4 Pelatihan dan Akurasi Validasi

Akurasi dan validasi diukur menggunakan nilai-nilai yang berbeda pada saat pelatihan model. Percobaan dilakukan pada Google Collaboratory dengan RAM sebesar 12,50 GB. Dalam Tabel 1 diperlihatkan hasil percobaan dengan nilai-nilai parameter yang berbeda-beda.

Kinerja diukur melalui nilai-nilai yang berbeda pada jumlah *epoch* yang digunakan, *learning rate*, dan *dropout rate*. Kinerja model diukur dan diverifikasi pada citra Bangunan Adat Melayu.

#### 4 Kesimpulan

Studi ini telah mengumpulkan citra Bangunan Adat Melayu yang selanjutnya dijadikan dataset dalam penelitian ini. Teknik *preprocessing*, augmentasi, *training*, dan *testing* diimplementasikan pada CNN arsitektur model VGG16. Model yang diusulkan dalam penelitian ini dibangun dan diuji kinerjanya. Setting parameter melalui pengubahan nilai *learning rate*, *dropout*, dan *epoch*. Akurasi tertinggi 98,77% dari 106 data yang diuji dicapai ketika menggunakan *learning rate* 0,001, *drop out* 0,20, dan *epoch* sebesar 25. Namun karena data kecil sangat memungkinkan terjadinya *overfitting*. Hal ini dikarenakan model yang terlalu kompleks dengan banyak parameter cenderung mempelajari pola yang sangat spesifik, termasuk noise atau informasi yang tidak relevan. Selain itu, kurangnya variasi dalam data membuat model kesulitan untuk menggeneralisasi pola yang lebih luas. Model juga berisiko belajar dari gangguan atau fitur yang tidak penting, yang justru mengurangi kemampuannya untuk mengenali pola umum pada data yang lebih besar atau berbeda.

#### 5 Pekerjaan Masa Depan

Penelitian selanjutnya dapat menggunakan arsitektur model CNN lainnya seperti InceptionV3, MobileNet, atau ResNet untuk kemungkinan mendapatkan akurasi yang lebih baik. Dalam penelitian selanjutnya akan dilakukan komparasi dengan metode-metode lainnya menggunakan data dalam bentuk video dengan teknik klasifikasi video untuk Bangunan Adat Melayu dengan menambah fitur ornamen/ukiran dan bentuk tampak bangunan secara keseluruhan dengan durasi maksimal 2 menit. Untuk mengatasi *overfitting* dapat dilakukan untuk penelitian selanjutnya menggunakan Regularisasi (seperti *drop-out* atau L2 regularization), Augmentasi data untuk memperbesar variasi, dan Teknik *Transfer learning* untuk memanfaatkan model yang sudah dilatih dengan data lebih besar.

#### Referensi

Abed, M. H., & Hussain, Z. M. (2021). Architectural heritage images classification using deep learning with CNN Architectural Heritage Images Classification Using Deep

Learning With CNN. *Proceedings of the 2nd International Workshop on Visual Pattern Extraction and Recognition for Cultural Heritage Understanding*, 1.

Ahdiani, U., Winiarti, S., Pramono, H., & Ismail, T. (2025). Collaboration of Digital Literacy and Artificial Intelligence in Preserving Traditional Malay House Culture. *E3S Web of Conferences*, 622, 1–8. <https://doi.org/10.1051/e3sconf/202562203008>

Alsheikh Mahmoud, S., & Bin Hashim, H. (2025). Traditional Malay House Preservation: Guidelines for Structural Evaluation. *Buildings*, 15(5). <https://doi.org/10.3390/buildings15050782>

Bashaddadh, O., Omar, N., Mohd, M., & Khalid, M. N. A. (2025). Machine Learning and Deep Learning Approaches for Fake News Detection: A Systematic Review of Techniques, Challenges, and Advancements. *IEEE Access*, 13(May), 90433–90466. <https://doi.org/10.1109/ACCESS.2025.3572051>

Devi Yunita, & Maulana Fansyuri. (2025). Analisis Kinerja Algoritma Logistic Regression Dalam Klasifikasi Citra Wajah Berdasarkan Fitur Citra Warna Dan Bentuk. *Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer*, 5(2), 48–56. <https://doi.org/10.55606/teknik.v5i2.7200>

Fawwaz, I., Yennimar, Y., Dharsinni, N. P., & Wijaya, B. A. (2023). The Optimization of CNN Algorithm Using Transfer Learning for Marine Fauna Classification. *Sinkron*, 8(4), 2236–2245. <https://doi.org/10.33395/sinkron.v8i4.12893>

Fu, D. S., Huang, J., Hazra, D., Dwivedi, A. K., Gupta, S. K., Shrivahare, B. D., & Garg, D. (2024). Enhancing sports image data classification in federated learning through genetic algorithm-based optimization of base architecture. In *PLoS ONE* (Vol. 19, Issue 7 July). <https://doi.org/10.1371/journal.pone.0303462>

Janković, R. (2020). Machine learning models for cultural heritage image classification: Comparison based on attribute selection. *Information* (Switzerland), 11(1). <https://doi.org/10.3390/info11010012>



- Jiang, Z. P., Liu, Y. Y., Shao, Z. E., & Huang, K. W. (2021). An improved VGG16 model for pneumonia image classification. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/app112311185>
- Kevseroglu, O., & Kurban, R. (2024). Re-exploring the Kayseri Culture Route by Using Deep Learning for Cultural Heritage Image Classification. *Cultural Heritage Image Classification by Using Deep Learning: Kayseri Culture Route. ACM International Conference Proceeding Series*, 196–201. <https://doi.org/10.1145/3660853.3660913>
- Li, H., & Dong, H. (2025). Architectural Style Classification Based on Deep Learning. *Computer-Aided Design and Applications*, 22, 16–31. <https://doi.org/10.14733/cadaps.2025.S1.1.6-31>
- Li, S., Wu, C., & Xiong, N. (2022). Hybrid Architecture Based on CNN and Transformer for Strip Steel Surface Defect Classification. *Electronics (Switzerland)*, 11(8), 1–14. <https://doi.org/10.3390/electronics11081200>
- Lydia, A. A., & Chandrasekar, S. (2022). A Comparative Study on Regularization Techniques in Convolutional Neural Networks. *International Journal of Research in Engineering and Science (IJRES) ISSN*, 10(7), 784–793.
- Malhotra, R., & Singh, P. (2023). Recent advances in deep learning models: a systematic literature review. In *Multimedia Tools and Applications* (Vol. 82, Issue 29). Springer US. <https://doi.org/10.1007/s11042-023-15295-z>
- Mall, P. K., Singh, P. K., Srivastav, S., Narayan, V., Paprzycki, M., Jaworska, T., & Ganzha, M. (2023). A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities. *Healthcare Analytics*, 4(June), 100216. <https://doi.org/10.1016/j.health.2023.100216>
- Maulidi, M. R., Indriani, F., Farmadi, A., Budiman, I., & Kartini, D. (2024). Optimizing South Kalimantan Food Image Classification Through CNN Fine-Tuning. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika (JITEKI)*, 10(4), 897–913. <https://doi.org/10.26555/jiteki.v10i4.30325>
- Mustafid, A., Pamuji, M. M., & Helmiyah, S. (2020). A Comparative Study of Transfer Learning and Fine-Tuning Method on Deep Learning Models for Wayang Dataset Classification. *IJID (International Journal on Informatics for Development)*, 9(2), 100–110. <https://doi.org/10.14421/ijid.2020.09207>
- Poojary, R., Raina, R., & Mondal, A. K. (2021). Effect of data-augmentation on fine-tuned cnn model performance. *IAES International Journal of Artificial Intelligence*, 10(1), 84–92. <https://doi.org/10.11591/ijai.v10.i1.pp84-92>
- Shehata, A. M., & Alaboud, N. S. (2025). Identification of Features of Architectural Heritage Using Deep Learning Techniques. *Civil Engineering and Architecture*, 13(4), 3280–3298. <https://doi.org/10.13189/cea.2025.130431>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Su, Y. P., Hu, W. Y., Lin, J. W., Chen, Y. C., Sezer, S., & Chen, S. J. (2011). Low power Gm-boosted differential Colpitts VCO. *International System on Chip Conference*, 247–250. <https://doi.org/10.1109/SOCC.2011.6085109>
- Winiarti, S., Pramono, H., & Pranolo, A. (2022). Application of Artificial Intelligence in Digital Architecture to Identify Traditional Javanese Buildings. *Journal of Artificial Intelligence in Architecture*, 1(1), 20–29. <https://doi.org/10.24002/jarina.v1i1.4916>
- Yoshimura, Y., Cai, B., Wang, Z., & Ratti, C. (2019). Deep learning architect: Classification for architectural design through the eye of artificial intelligence. *Lecture Notes in Geoinformation and Cartography*, 249–265. [https://doi.org/10.1007/978-3-030-19424-6\\_14](https://doi.org/10.1007/978-3-030-19424-6_14)
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. In *Artificial Intelligence Review*



(Vol. 57, Issue 4). Springer Netherlands.  
<https://doi.org/10.1007/s10462-024-10721-6>

