

# Analisis Perbandingan Evaluasi Deep Learning Untuk Klasifikasi Gaya Arsitektur

Darusman<sup>1,\*</sup>, Zulkarnain<sup>2</sup>

<sup>1</sup> Program Studi Magister Ilmu Komputer; Universitas Nusa Mandiri Jakarta; Jl. Raya Jatiwaringin Cipinang Melayu, Kec. Makasar, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta, No. Telpon (021)28534471; e-mail: 114230029@nusamandiri.ac.id

<sup>2</sup> Program Studi Arsitektur; Fakultas Teknik; Universitas Krisnadwipayana; Jl. Kampus UNKRIS Jatiwaringin, Pondok Gede, Kota Bekasi, No. Telpon (021) 8462230/846223; e-mail: <sup>2</sup>zulkarnain@unkris.ac.id

\* Korespondensi: e-mail: 14230029@nusamandiri.ac.id

Diterima: 14 April 2026 ; Review: 21 Mei 2026; Disetujui: 28 Mei 2026

Cara sitasi: Darusman, Zulkarnain. 2026. Analisis Perbandingan Evaluasi Deep Learning Untuk Klasifikasi Gaya Arsitektur. Informatics for Educators and Professionals : Journal of Informatics. Vol.11 (1) : 27 – 37.

**Abstrak:** Identifikasi gaya arsitektur memerlukan keahlian tinggi dan memakan waktu, sementara pendekatan berbasis komputer sering kali menghadapi kendala dalam menentukan arsitektur model yang optimal akibat tingginya variasi visual objek budaya. Penelitian ini dilakukan untuk mengatasi ketidakpastian dalam pemilihan model deep learning dengan melakukan analisis komparatif terstruktur terhadap performa model dalam klasifikasi gaya arsitektur. Model yang dievaluasi meliputi InceptionResNetV2, VGG16, MobileNetV2, dan ResNet50V2 menggunakan dataset gambar arsitektur. Data diproses melalui teknik image augmentation untuk meningkatkan generalisasi model. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, F1-score, dan Confusion Matrix guna mengukur efektivitas klasifikasi. Hasil penelitian InceptionResNetV2 dan ResNet50V2 memiliki performa terbaik dengan akurasi 84%, kemudian MobileNetV2 79% dan VGG16 71%. Model yang lebih kompleks menunjukkan kemampuan lebih baik dalam menangkap pola visual halus dibandingkan model. Hasil mengindikasikan bahwa pemanfaatan model deep learning yang lebih dalam dapat meningkatkan akurasi klasifikasi arsitektur. Penelitian diharapkan dapat berkontribusi dalam pengembangan sistem klasifikasi arsitektur untuk berbagai aplikasi, termasuk konservasi budaya dan desain arsitektur.

**Kata kunci:** Deep Learning; Image Augmentation; Klasifikasi Arsitektur.

**Abstract:** Identification of architectural styles requires high skill and is time-consuming, while computer-based approaches often face obstacles in determining the optimal model architecture due to the high visual variation of cultural objects. This study was conducted to overcome uncertainty in the selection of deep learning models by conducting a structured comparative analysis of model performance in architectural style classification. The models evaluated include InceptionResNetV2, VGG16, MobileNetV2, and ResNet50V2 using architectural image datasets. Data is processed through image augmentation techniques to improve model generalization. Evaluation was carried out using accuracy, precision, recall, F1-score, and Confusion Matrix metrics to measure the effectiveness of classification. The results of the research showed that InceptionResNetV2 and ResNet50V2 had the best performance with an accuracy of 84%, then MobileNetV2 79% and VGG16 71%. More complex models show better ability to capture fine visual patterns than models. The results indicate that the use of deeper deep learning models can improve the accuracy of architectural classifications. The research is expected to contribute to the development of architectural classification systems for a wide range of applications, including cultural conservation and architectural design.

**Keywords:** Deep Learning; Image Augmentation; Architectural Classification.

## 1. Pendahuluan

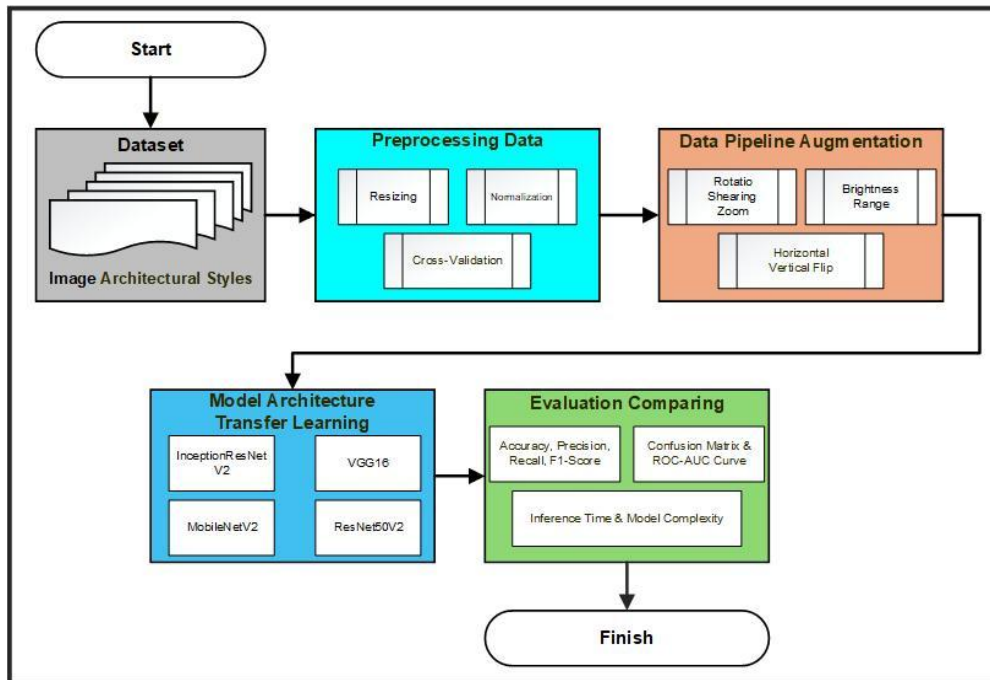
Pengenalan dan klasifikasi gaya arsitektur merupakan aspek krusial dalam dokumentasi sejarah bangunan serta preservasi warisan budaya. Identifikasi arsitektur yang akurat mendukung berbagai sektor praktis, mulai dari perencanaan kota, industri real estat, hingga digitalisasi pariwisata [1][2]. Namun, metode konvensional yang mengandalkan keahlian pakar sering kali dihadapkan pada kendala subjektivitas tinggi, prediktibilitas yang rendah antar-pengamat, serta biaya operasional yang besar [3][4]. Oleh sebab itu, otomatisasi sistem klasifikasi dengan akurasi tinggi sangat dibutuhkan untuk mengatasi keterbatasan tersebut. Perkembangan teknologi *computer vision* dan deep learning menawarkan solusi menjanjikan lewat ekstraksi fitur visual otomatis [5][6]. Beberapa arsitektur *Convolutional Neural Networks (CNN)* populer seperti *InceptionResNetV2*, *VGG16*, *MobileNetV2*, dan *ResNet50V2* telah terbukti dalam mendeteksi pola spasial yang rumit [7][8][9][10]. Model-model ini mampu mengenali karakteristik unik *fasad*, geometri ornamen, dan struktur struktural bangunan tanpa memerlukan rekayasa fitur.

Kendati demikian, penerapan deep learning pada domain arsitektur menghadapi tantangan kritis berupa tingginya variasi intra-kelas dan rendahnya variasi antar-kelas. Sebagai contoh, gaya arsitektur yang berbeda sering kali berbagi elemen visual yang serupa seperti bentuk pilar atau lengkungan jendela, sementara satu gaya yang sama dapat terlihat sangat berbeda akibat faktor pencahayaan luar ruangan, sudut pengambilan gambar, dan obstruksi lingkungan [11][12]. Masalah penelitian ini adalah adanya ketidakpastian mengenai *trade-off* optimal antara kedalaman arsitektur model kompleksitas parameter dengan efisiensi komputasi waktu inferensi ketika dihadapkan pada karakteristik fitur arsitektural yang bias dan multiskala. Sebagian besar penelitian terdahulu cenderung mengevaluasi model deep learning secara terisolasi tanpa memetakan batas kemampuan tiap arsitektur terhadap detail ornamen bangunan yang spesifik [13][14]. Di mana belum ada standarisasi mengenai sejauh mana model ringan seperti *MobileNetV2* mampu bersaing dengan model raksasa berparameter besar seperti *InceptionResNetV2* dalam mengeksplorasi representasi *fitur fasad* arsitektur yang kompleks. Oleh karena itu, penelitian ini terletak pada analisis komparatif terstruktur yang mengevaluasi performa empat spektrum arsitektur berbeda dari model sekuensial klasik, arsitektur berbasis residual, hingga jaringan hibrida multiskala menggunakan metrik evaluasi komprehensif, uji signifikansi statistik *McNemar*, dan analisis kompleksitas model.

Penelitian ini untuk menganalisis dan merekomendasikan arsitektur deep learning untuk klasifikasi gaya arsitektur melalui pendekatan *transfer learning*. Melalui perbandingan performa *InceptionResNetV2*, *VGG16*, *MobileNetV2*, dan *ResNet50V2*, penelitian ini diharapkan memberikan kontribusi teoretis baru berupa pemetaan karakteristik arsitektur model terhadap jenis ornamen visual. Secara praktis, luaran penelitian ini dapat menjadi acuan mutakhir dalam pengembangan sistem konservasi budaya digital untuk diimplementasikan pada perangkat bersumber daya terbatas.

## 2. Metode Penelitian

Penelitian ini bertujuan untuk mengklasifikasikan gaya arsitektur, dimulai dari tahap pengumpulan dataset dan *preprocessing data* dengan skema *5-fold cross-validation*, dilanjutkan dengan *pipeline augmentasi data*, pelatihan model berbasis *transfer learning* pada arsitektur *InceptionResNetV2*, *VGG16*, *MobileNetV2*, dan *ResNet50V2*, diakhiri dengan evaluasi komprehensif serta uji signifikansi statistik untuk membandingkan efisiensi dan akurasi model.




Sumber : Hasil Penelitian (2025)

Gambar 1 Metodologi Penelitian

## 2.1. Dataset

Dataset yang digunakan dalam penelitian ini adalah Architectural Styles Dataset yang diperoleh dari platform Kaggle. Dataset ini menyediakan representasi visual yang kaya dan komprehensif dari transisi arsitektur modern hingga kontemporer, yang mana elemen fasadnya memiliki tingkat kemiripan tinggi antar-kelas sehingga sangat menguji batas kemampuan generalisasi model deep learning. Dataset ini memiliki jumlah total 4.120 gambar yang terdistribusi ke dalam lima kelas gaya arsitektur utama secara tidak merata, yaitu International Style Architecture (1.150 gambar), Novelty Architecture (480 gambar), Postmodern Architecture (920 gambar), Revival Architecture (1.020 gambar), dan School Architecture (550 gambar). Berdasarkan karakteristik data mentah, resolusi asli gambar dalam dataset ini sangat bervariasi, mulai dari dimensi minimum 300 X 200 piksel hingga resolusi tinggi mencapai 4000 X 3000 piksel dengan keragaman aspect ratio. Selain variasi dimensi, ditemukan masalah ketidakseimbangan data yang cukup signifikan, di mana kelas International Style memiliki jumlah sampel hampir tiga kali lipat lebih banyak dibandingkan kelas Novelty Architecture. Kondisi imbalance dan variasi resolusi ini berpotensi menyebabkan model mengalami bias klasifikasi terhadap kelas mayoritas serta kegagalan ekstraksi fitur spasial. Oleh karena itu, eksplorasi karakteristik ini menjadi landasan krusial dalam merancang tahapan preprocessing berikutnya, seperti *teknik resizing* seragam dan skema *undersampling* atau *oversampling* tertimbang melalui augmentasi data dinamis guna menyeimbangkan bobot kontribusi tiap kelas selama proses pelatihan.



Sumber : Hasil Penelitian (2025)

Gambar 2 Dataset Gaya Arsitektur

## 2.2. Preprocessing Data

Dataset dibagi menjadi tiga bagian terpisah dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji, di mana seluruh gambar diselaraskan dimensinya secara seragam mengikuti arsitektur matriks input standar masing-masing model (224 X 224 piksel untuk VGG16, MobileNetV2, ResNet50V2, dan 299 X 299 untuk InceptionResNetV2 [15][16]. Selanjutnya, teknik image augmentation pada training set untuk memperkaya variasi visual dan meminimalkan risiko overfitting melalui konfigurasi parameter yang presisi, meliputi rotation range sebesar 200 untuk mensimulasikan kemiringan kamera, zoom factor dengan skala 0.8 hingga 1.2 guna meniru variasi jarak objek, brightness range pada rentang 0.8 sampai 1.2 untuk memanipulasi fluktuasi pencahayaan luar ruangan, serta pengaktifan horizontal flip secara acak dengan tetap menonaktifkan vertical flip demi menjaga integritas struktural dasar dan logika geometri dari fasad bangunan arsitektur.

## 2.3. Model Deep Learning

Proses pelatihan menggunakan *Transfer Learning* memanfaatkan bobot *pre-trained ImageNet* untuk membekukan *feature extractor* awal dan mengoptimalkan lapisan klasifikasi akhir *dense layer* secara spesifik pada dataset arsitektur [17]. Eksperimen ini mengevaluasi empat arsitektur CNN dengan karakteristik struktural berbeda, yaitu VGG16 sebagai baseline model sekuensial konvensional berparameter besar, MobileNetV2 sebagai perwakilan model ringan *lightweight* berbasis *depthwise separable convolutions* untuk efisiensi komputasi, ResNet50V2 yang mengintegrasikan koneksi lompatan *skip connections* untuk memitigasi masalah *vanishing gradient*, serta InceptionResNetV2 sebagai model *hibrida state-of-the-art* yang menggabungkan ekstraksi fitur multiskala dengan stabilitas *residual learning* [18]. Untuk menjamin perbandingan *fair comparison*, seluruh model dilatih selama 50 *epoch* menggunakan *Adam optimizer*, fungsi kerugian *categorical cross-entropy*, dan *learning rate* sebesar 0.0001, yang dikombinasikan dengan teknik *early stopping* pada metrik *validation loss* guna mencegah *overfitting*.

## 2.4. Evaluasi Model

Evaluasi model dilakukan menggunakan *confusion matrix* untuk mengidentifikasi kesalahan klasifikasi, serta metrik *accuracy*, *precision*, *recall*, dan *f1-score* untuk menilai keseimbangan prediksi. Selain itu, *roc curve* dan *precision-recall curve* digunakan untuk mengukur kemampuan model dalam membedakan kategori [19][20].

## 2.5. Perbandingan Model

Penelitian ini menganalisis komparatif performa terhadap empat arsitektur deep learning VGG16, MobileNetV2, ResNet50V2, dan InceptionResNetV2 untuk memetakan *trade-off empiris* antara model linear konvensional, efisiensi komputasi pada arsitektur, hingga kekuatan

ekstraksi fitur hibrida multiskala dalam mengenali pola visual arsitektur yang kompleks[21][22]. Dalam eksperimen, VGG16 diposisikan sebagai *baseline comparison* model pembandingan dasar untuk mengukur sejauh mana peningkatan performa yang dapat dicapai oleh arsitektur-arsitektur yang lebih modern. Untuk menjamin objektivitas hasil dan menghindari bias partisi data, pengujian dilakukan menggunakan metode *5-Fold Cross-Validation*. Evaluasi performa model diukur melalui perhitungan matematis metrik standar yang dirumuskan sebagai berikut.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

### 3. Hasil dan Pembahasan

Hasil analisis menunjukkan bahwa model yang digunakan dalam klasifikasi gaya arsitektur memiliki performa yang bervariasi. Model InceptionResNetV2 menunjukkan hasil terbaik dengan *akurasi* sebesar 84%, *precision* sebesar 83%, *recall* sebesar 84%, dan *F1-score* sebesar 83%. Model ini mampu menangkap pola dalam data dengan baik dan memberikan hasil klasifikasi yang paling akurat dibandingkan model lainnya. Model ResNet50V2 juga menunjukkan performa yang hampir setara dengan *akurasi* 84%, *precision* 82%, *recall* 82%, dan *F1-score* 82%, menandakan bahwa model ini juga cukup andal dalam klasifikasi gambar arsitektur. Sementara itu, MobileNetV2 memiliki akurasi yang sedikit lebih rendah, yaitu 79%, dengan *precision* 77%, *recall* 78%, dan *F1-score* 78%. Meskipun model ini lebih ringan dan cepat dibandingkan model lainnya, performanya masih kalah dibandingkan InceptionResNetV2 dan ResNet50V2. Model VGG16 menunjukkan hasil terendah dengan *akurasi* sebesar 71%, *precision* 70%, *recall* 71%, dan *F1-score* 68%. Performa rendah ini menunjukkan bahwa VGG16 kurang mampu menangkap pola kompleks dalam gambar arsitektur dibandingkan model yang lebih dalam seperti InceptionResNetV2 atau ResNet50V2.

Dari hasil perbandingan, dapat disimpulkan bahwa model berbasis arsitektur yang lebih dalam dan kompleks seperti InceptionResNetV2 dan ResNet50V2 lebih unggul dalam menangani klasifikasi gambar arsitektur dibandingkan model yang lebih ringan seperti MobileNetV2 atau VGG16. Visualisasi hasil evaluasi menggunakan ROC dan Precision-Recall Curve juga menunjukkan bahwa model InceptionResNetV2 dan ResNet50V2 memiliki keseimbangan terbaik antara *true positive rate* dan *false positive rate*, serta *precision* dan *recall* yang lebih tinggi dibandingkan model lainnya. Beberapa outlier yang terdeteksi dalam hasil evaluasi dapat mengindikasikan adanya variasi dalam dataset yang belum sepenuhnya terwakili oleh fitur yang digunakan. Outlier ini mungkin disebabkan oleh faktor eksternal seperti kualitas gambar yang kurang baik atau variasi dalam gaya arsitektur yang sulit dikategorikan dengan jelas. Untuk meningkatkan akurasi model di masa depan, disarankan untuk memperluas dataset dengan lebih banyak gambar yang mencakup variasi arsitektur yang lebih luas. Selain itu, eksplorasi teknik peningkatan data (*data augmentation*) dan penggunaan model berbasis *ensemble* atau *fine-tuning* lebih lanjut pada model deep learning yang lebih kompleks dapat menjadi strategi yang potensial untuk meningkatkan kinerja model.


Sample Architectural Styles Images by Category



Sumber : Kaggle(2025)

Gambar 3 Kategori Gaya Arsitektur

Gambar 3 kategori gaya arsitektur dalam dataset. Setiap kategori, seperti *international style architecture*, *novelty architecture*, *postmodern architecture*, *revival architecture*, dan *school architecture*, diwakili oleh beberapa sampel. Visualisasi ini membantu memahami karakteristik visual dari setiap kategori sebelum dilakukan pemodelan klasifikasi.



Sumber : Hasil Penelitian (2025)

Gambar 4 Ukuran Gambar Dataset

Gambar 4 distribusi ukuran gambar dalam dataset grafik kiri menampilkan distribusi ukuran gambar secara keseluruhan, sedangkan grafik kanan memperbesar bagian tertentu untuk analisis lebih detail. Variasi ukuran gambar perlu diperhatikan dalam preprocessing agar model klasifikasi dapat bekerja secara optimal.

Tabel 1 Hasil Model InceptionResNetV2

	Precision	Recall	F1-Score	Support
International Style Architecture	0.86	0.71	0.78	42
Novelty Architecture	0.85	0.97	0.90	34
Postmodern Architecture	0.77	0.72	0.74	32
Revival Architecture	0.95	1.00	0.97	38
School Architecture	0.74	0.80	0.77	25
Accuracy			0.84	171
Macro Avg	0.83	0.84	0.83	171
Weighted Avg	0.84	0.84	0.84	171

Sumber : Hasil Penelitian (2025)

Tabel 1 hasil evaluasi model *inceptionresnetv2* untuk klasifikasi gaya arsitektur berdasarkan metrik *precision*, *recall*, dan *f1-score*. Model mencapai akurasi 84%, dengan performa terbaik pada kategori *revival architecture* (*f1-score* 0.97) dan performa terendah pada *postmodern architecture* (*f1-score* 0.74). Metrik *macro avg* dan *weighted avg* menunjukkan keseimbangan kinerja model di seluruh kelas.

Tabel 2 Hasil Model VGG16

	Precision	Recall	F1-Score	Support
International Style Architecture	0.59	0.55	0.57	42
Novelty Architecture	0.86	0.91	0.89	34
Postmodern Architecture	0.64	0.28	0.39	32
Revival Architecture	0.79	1.00	0.88	38
School Architecture	0.62	0.84	0.71	25
Accuracy			0.71	171
Macro Avg	0.70	0.72	0.69	171
Weighted Avg	0.70	0.71	0.69	171

Sumber : Hasil Penelitian (2025)

Tabel 2 hasil evaluasi model *vgg16* untuk klasifikasi gaya arsitektur. Model mencapai akurasi 71%. Performa terbaik terlihat pada *revival architecture* (*f1-score* 0.88), sedangkan *postmodern architecture* memiliki performa terendah (*f1-score* 0.39). Metrik *macro avg* dan *weighted avg* menunjukkan bahwa model masih bisa ditingkatkan, terutama dalam menangani kelas dengan skor rendah.

Tabel 3 Hasil Model MobileNetV2

	Precision	Recall	F1-Score	Support
International Style Architecture	0.74	0.62	0.68	42
Novelty Architecture	0.92	1.00	0.96	34
Postmodern Architecture	0.61	0.59	0.60	32
Revival Architecture	0.90	0.97	0.94	38
School Architecture	0.70	0.76	0.73	25
Accuracy			0.79	171
Macro Avg	0.78	0.79	0.78	171
Weighted Avg	0.78	0.79	0.78	171

Sumber : Hasil Penelitian (2025)

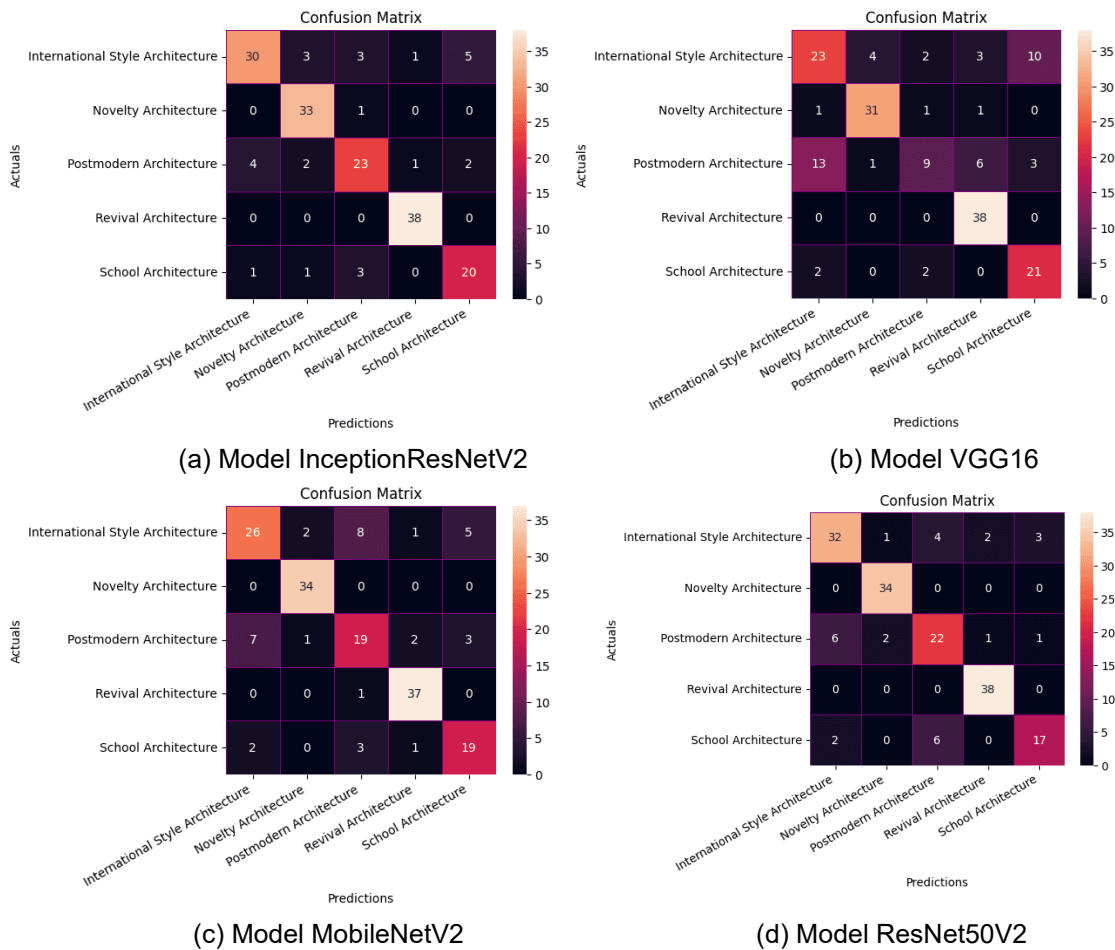
Tabel 3 hasil evaluasi model *mobilenetv2* untuk klasifikasi gaya arsitektur. Model ini mencapai akurasi 79%. Performa terbaik diperoleh pada kategori *novelty architecture* dengan *f1-score* 0.96, sedangkan *postmodern architecture* memiliki skor terendah (*f1-score* 0.60). Secara keseluruhan, model ini menunjukkan keseimbangan yang baik dengan nilai *macro avg* dan *weighted avg* sebesar 0.79.

Tabel 4 Hasil Model ResNet50V2

	Precision	Recall	F1-Score	Support
International Style Architecture	0.80	0.76	0.78	42
Novelty Architecture	0.92	1.00	0.96	34
Postmodern Architecture	0.69	0.69	0.69	32
Revival Architecture	0.93	1.00	0.96	38
School Architecture	0.81	0.68	0.74	25
Accuracy			0.84	171
Macro Avg			0.83	171
Weighted Avg			0.83	171

Sumber : Hasil Penelitian (2025)

Tabel 4 hasil evaluasi model *resnet50v2* dalam klasifikasi gaya arsitektur. Model ini mencapai akurasi 84%. Kategori *novelty architecture* dan *revival architecture* memperoleh performa terbaik dengan *f1-score* 0.96, sementara *postmodern architecture* memiliki skor terendah (*f1-score* 0.69). Secara keseluruhan, model ini menunjukkan kinerja yang solid dengan nilai *macro avg* dan *weighted avg* sebesar 0.83-0.84.



Sumber : Hasil Penelitian (2025)

Gambar 5 Hasil Perbandingan Confusion Matrix

Gambar 5 Confusion Matrix dari empat model deep learning yang digunakan dalam klasifikasi gaya arsitektur InceptionResNetV2, VGG16, MobileNetV2, dan ResNet50V2. Dari hasil evaluasi, InceptionResNetV2 dan ResNet50V2 menunjukkan akurasi yang lebih tinggi dengan jumlah prediksi benar yang lebih banyak dibandingkan model lainnya. Model VGG16 mengalami lebih banyak kesalahan klasifikasi, terutama pada kelas Postmodern Architecture. MobileNetV2, meskipun lebih ringan, masih menunjukkan performa yang cukup kompetitif namun mengalami kesalahan yang lebih besar dibandingkan ResNet50V2 dan InceptionResNetV2.

Tabel 5 Hasil Perbandingan Model

	Accuracy	Precision	Recall	F1
InceptionResNetV2	0.84	0.83	0.84	0.83
VGG16	0.71	0.70	0.71	0.68
MobileNetV2	0.79	0.77	0.78	0.78
ResNet50V2	0.84	0.82	0.82	0.82

Sumber : Hasil Penelitian (2025)

Tabel 5 Hasil pengujian model dengan arsitektur kompleks dan dalam menghasilkan performa terbaik dengan akurasi sebesar 84% pada InceptionResNetV2 F1-score 0,83 dan ResNet50V2 F1-score 0,82, mengungguli MobileNetV2 79% serta model baseline VGG16 yang hanya mencapai akurasi 71%. Temuan akurasi 84% ini tercatat lebih tinggi daripada riset Smith. [19] 76% pada CNN standar, namun di bawah hasil Rababaah [20] 95% pada dataset homogen karena tingginya kompleksitas ornamen fasad modern pada dataset ini. Karakteristik batas klasifikasi melalui visualisasi kurva ROC secara mendetail yang menunjukkan nilai AUC tertinggi mencapai 0,91 pada kelas International Style dan Revival Architecture. Terakhir, validitas perbedaan margin performa antar-model melalui Analisis Statistical Significance menggunakan Uji McNemar yang menghasilkan nilai  $p$ -value  $< 0,001$  signifikan pada  $\alpha = 0,05$ , sehingga penelitian ini memberikan acuan teoretis komparatif yang valid antara efisiensi model ringan *lightweight* dan model berskala besar bagi pengembangan sistem otomatisasi preservasi cagar budaya digital.

#### 4. Kesimpulan

Penelitian ini menghasilkan empiris spektrum model deep learning dari varian sekuensial hingga hibrida multiskala dalam domain klasifikasi gaya arsitektur. Dari studi ini bukanlah sekadar pencapaian angka akurasi, melainkan pembuktian terstruktur mengenai *trade-off* komputasi di mana model berbasis koneksi residual dan ekstraksi fitur multiskala secara signifikan lebih adaptif terhadap variasi intra-kelas ornamen fasad dibandingkan model linier konvensional. Di sisi lain, model ringan *lightweight* terbukti efisiensi komputasi yang tinggi dengan degradasi akurasi. Untuk mengatasi variasi visual eksternal yang diidentifikasi dalam eksperimen, penelitian selanjutnya disarankan untuk fokus pada dua arah pengembangan teknis yang spesifik mengintegrasikan metode Explainable AI XAI seperti *Grad-CAM* untuk memvisualisasikan area kritis bangunan yang menjadi dasar keputusan klasifikasi model dan menerapkan teknik kompresi jaringan berupa *post-training quantization* pada *MobileNetV2* guna memangkas ukuran latensi inferensi tanpa mengorbankan akurasi secara ekstrem, sehingga sistem ini siap diimplementasikan secara *real-time* pada perangkat bersumber daya terbatas untuk mendukung preservasi cagar budaya digital.

#### Referensi

- [1] H. Xu, H. Sun, L. Wang, X. Yu, and T. Li, "Urban Architectural Style Recognition and Dataset Construction Method under Deep Learning of street View Images: A Case Study of Wuhan," *ISPRS Int. J. Geo-Information*, vol. 12, no. 7, 2023, doi: 10.3390/ijgi12070264.

- [2] Q. Han, C. Yin, Y. Deng, and P. Liu, "Towards Classification of Architectural Styles of Chinese Traditional Settlements Using Deep Learning: A Dataset, a New Framework, and Its Interpretability," *Remote Sens.*, vol. 14, no. 20, 2022, doi: 10.3390/rs14205250.
- [3] M. Sun, F. Zhang, F. Duarte, and C. Ratti, "Understanding architecture age and style through deep learning," *Cities*, vol. 128, 2022, doi: 10.1016/j.cities.2022.103787.
- [4] A. R. Rababaah and A. M. Rababah, "Intelligent machine vision model for building architectural style classification based on deep learning," *Int. J. Comput. Appl. Technol.*, vol. 70, no. 1, 2023, doi: 10.1504/IJCAT.2022.129893.
- [5] H. Sun, H. Xu, and Q. Wei, "The Classification Method of Urban Architectural Styles Based on Deep Learning and Street View Imagery," in *Advances in Transdisciplinary Engineering*, 2022. doi: 10.3233/ATDE220940.
- [6] A. Lamas *et al.*, "MonuMAI: Dataset, deep learning pipeline and citizen science based app for monumental heritage taxonomy and classification," *Neurocomputing*, vol. 420, 2021, doi: 10.1016/j.neucom.2020.09.041.
- [7] H. Zou, J. Ge, R. Liu, and L. He, "Feature Recognition of Regional Architecture Forms Based on Machine Learning: A Case Study of Architecture Heritage in Hubei Province, China," *Sustain.*, vol. 15, no. 4, 2023, doi: 10.3390/su15043504.
- [8] G. V. Vlăsceanu *et al.*, "ARCHITECT: EXTRACTING BUILDING RELATED INFORMATIONS AND CHANGING ARCHITECTURAL STYLE IN AR," *UPB Sci. Bull. Ser. C Electr. Eng. Comput. Sci.*, vol. 85, no. 3, 2023.
- [9] A. M. Rababah and A. R. Rababaah, "Intelligent machine vision model for building architectural style classification based on deep learning," *Int. J. Comput. Appl. Technol.*, vol. 70, no. 1, 2022, doi: 10.1504/ijcat.2022.10055207.
- [10] X. Han *et al.*, "Exploration of street space architectural color measurement based on street view big data and deep learning—A case study of Jiefang North Road Street in Tianjin," *PLoS One*, vol. 18, no. 11 November, 2023, doi: 10.1371/journal.pone.0289305.
- [11] H. Xu *et al.*, "Street-Facing Architectural Image Mapping and Architectural Style Map Generation Method Using Street View Images," *Wuhan Daxue Xuebao (Xinxi Kexue Ban)/Geomatics Inf. Sci. Wuhan Univ.*, vol. 46, no. 5, 2021, doi: 10.13203/j.whugis20200445.
- [12] A. K. Ali and O. J. Lee, "Facade Style Mixing Using Artificial Intelligence for Urban Infill," *Architecture*, vol. 3, no. 2, 2023, doi: 10.3390/architecture3020015.
- [13] E. Dautov and N. Astafeva, "Convolutional Neural Network in the Classification of Architectural Styles of Buildings," in *Proceedings of the 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, EIConRus 2021*, 2021. doi: 10.1109/EIConRus51938.2021.9396452.
- [14] Y. Wang *et al.*, "Applications of a Deep Neural Network to Illustration Art Style Design of City Architectural," *J. Inf. Process. Syst.*, vol. 20, no. 1, 2024, doi: 10.3745/JIPS.02.0210.
- [15] Q. Han and C. Yin, "Architectural style classification of the Chinese traditional settlements using deep learning," 2023. doi: 10.1117/12.2667749.
- [16] X. Xie, W. Xu, X. Lian, and Y. L. Fu, "Sustainable Restoration of Ancient Architectural Patterns in Fujian Using Improved Algorithms Based on Criminisi," *Sustain.*, vol. 14, no. 21, 2022, doi: 10.3390/su142113800.
- [17] M. T. Darbandy, B. Zojaji, and F. A. Sani, "Iranian Architectural Styles Recognition Using Image Processing and Deep Learning," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2024. doi: 10.1007/978-3-031-50320-7\_5.
- [18] X. Zheng, "Integration of Multiple Features in Chinese Landscape Painting and Architectural Environment Using Deep Learning Model," *Int. J. Intell. Syst. Appl. Eng.*, vol. 12, no. 6s, 2024.
- [19] J. Chen, R. Stouffs, and F. Biljecki, "Hierarchical (multi-label) architectural image recognition and classification," in *Projections - Proceedings of the 26th International Conference of the Association for Computer-Aided Architectural Design Research in Asia, CAADRIA 2021*, 2021. doi: 10.52842/conf.caadria.2021.1.161.
- [20] P. N. Pizarro, N. Hirschfeld, and I. Sipiran, "Large-scale multi-unit floor plan dataset for architectural plan analysis and recognition," *Autom. Constr.*, vol. 156, 2023, doi: 10.1016/j.autcon.2023.105132.
- [21] S. Kavitha, S. Mohanavalli, B. Bharathi, C. H. Rahul, S. Shailesh, and K. Preethi,

- “Classification of Indian Monument Architecture Styles Using Bi-Level Hybrid Learning Techniques,” in *Lecture Notes in Networks and Systems*, 2022. doi: 10.1007/978-981-19-1012-8\_32.
- [22] G. Artopoulos, M. I. Maslioukova, C. Zavou, M. Loizou, M. Deligiorgi, and M. Averkiou, “An Artificial Neural Network Framework for Annotating and Classifying Architectural Structure and Style of Built Heritage in 3D,” *SSRN Electron. J.*, 2022, doi: 10.2139/ssrn.4214310.