

Sistem Klasifikasi Citra Ai Dan Human Menggunakan CNN Multi-Modal Berbasis Web

Oscar Ardiyansyah^{1*}, Muhammad 'Aziz Hidayatullah², Derrylen Fernanda³
Syifa Nur Rakhmah⁴, Findi Ayu Sariasih⁵, Imam Sutoyo⁶

^{1,2,3,5}Informatika, Teknik Dan Informatika, Universitas Bina Sarana Informatika

^{4,6}Teknologi Informasi, Teknik Dan Informatika, Universitas Bina Sarana Informatika

*email: 15230205@bsi.ac.id¹

ABSTRACT

This research presents a web-based image classification system utilizing a multi-modal Convolutional Neural Network (CNN) architecture to distinguish between human-made and AI-generated images. The proposed system integrates three input types original image, Error Level Analysis (ELA), and Residual Noise Map (RDM) to enrich feature representation for classification. The model employs a pre-trained VGG16 backbone and is evaluated on a balanced dataset of 2,102 images. Experimental results indicate a validation accuracy of 91% and a macro F1-score of 0.91, showing a significant improvement over unimodal approaches for the same task. The system is implemented with the Flask framework, enabling real-time image authenticity analysis, making it suitable for deployment in digital forensics, copyright verification, and visual misinformation mitigation domains.

Keywords: AI Detection , CNN, ELA, Image Authenticity, Multi-Modal

ABSTRAK

Penelitian ini mengembangkan sistem klasifikasi citra berbasis web menggunakan arsitektur *Convolutional Neural Network* (CNN) multi-modal untuk membedakan citra buatan manusia dan hasil generatif AI. Sistem yang diajukan menggabungkan tiga jenis input, yaitu citra asli, *Error Level Analysis* (ELA), dan *Residual Noise Map* (RDM) guna memperkaya representasi fitur pada proses klasifikasi. Model dibangun dengan *backbone VGG16 pre-trained* dan diuji pada 2.102 data citra yang terbagi seimbang antara dua kelas. Hasil eksperimen menunjukkan akurasi validasi sebesar 91% dan nilai macro F1-score sebesar 0,91, mengungguli pendekatan unimodal pada tugas serupa. Sistem diimplementasikan menggunakan framework Flask yang memungkinkan uji keaslian citra secara *real-time*, sehingga sangat relevan diterapkan di bidang forensik digital, verifikasi hak cipta, dan mitigasi disinformasi visual.

Kata kunci: CNN, Deteksi AI , ELA , Keaslian Citra , Multi-Modal

PENDAHULUAN

Perkembangan kecerdasan buatan atau disebut dengan *Artificial Intelligence* (AI) telah berkembang pesat dan memiliki peran penting pada masa sekarang, AI juga dapat menggantikan peran manusia yang akan datang, karena dapat mensimulasikan pekerjaan manusia dalam melaksanakan tugas atau pekerjaan[1]. Salah satu hal yang bisa dilakukan adalah mengubah teks menjadi gambar atau *generate* gambar, banyak platform yang menyediakan ini seperti Dall-e, Stable diffusion, Midjourney, dan lainnya, yang memberikan manfaat yaitu menghasilkan gambar berkualitas, cepat dengan biaya yang murah. Selain membawa dampak positif terdapat pula dampak negatif yang dihasilkan oleh generatif gambar seperti deepfake antara lain penyebaran berita hoax, penyalahgunaan citra, dan disinformasi[2].

Cara berkembang sama dengan seperti cara belajar manusia, dengan mengumpulkan informasi dan pola yang dikumpulkan, dapat lebih cepat dan efisien dalam mencatat



informasi[3], salah satu cabang adalah deep learning yang digunakan untuk melakukan banyak hal seperti untuk memprediksi, mengenali objek hingga mendiagnosis penyakit. Pemanfaatan deep learning juga dapat digunakan untuk image processing, untuk membantu manusia mengenali objek dengan efisien, tepat dan cepat[3]. Penelitian ini menggunakan arsitektur *Convolutional Neural Network* (CNN) untuk membedakan citra asli dengan citra hasil generatif. Salah satu arsitektur CNN yang digunakan secara luas dalam penelitian pengolahan citra adalah *VGGnet-16*. Penelitian ini menggunakan *VGGnet-16* dikarenakan ia mampu untuk mengklasifikasikan citra imagenet dengan akurasi yang paling tinggi[4].

Penelitian kali ini membahas sebuah permasalahan bagaimana cara membedakan citra asli human dengan hasil generated, dikarenakan hasil metode konvensional masih belum mampu untuk mendeteksi citra hasil generatif[5]. Penelitian terdahulu telah menunjukkan hasil yang menjanjikan dalam deteksi citra sintesis, terutama dengan pendekatan deep learning. Misalnya, Subkhi et al. [6] menggunakan arsitektur *VGG19* untuk membedakan lukisan buatan manusia, dan mencapai akurasi tinggi pada data uji. Namun, penelitian tersebut menghadapi masalah overfitting akibat keterbatasan dataset dan pendekatan unimodal yang hanya memanfaatkan satu jenis input visual. Penelitian lain oleh Erwin et al. [7] mengeksplorasi arsitektur *Data-efficient Image Transformers* (DeiT) dan berhasil mencapai akurasi lebih dari 95% untuk klasifikasi ilustrasi 2D, namun belum sepenuhnya dievaluasi pada citra dunia nyata.

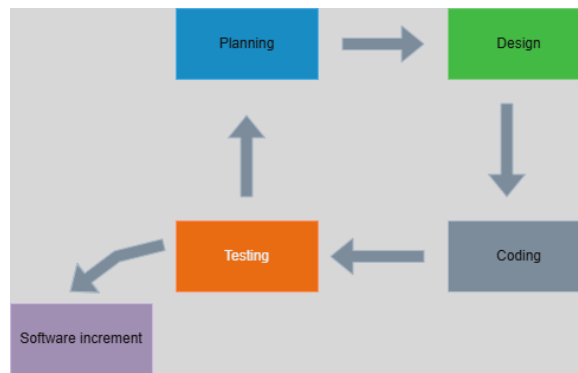
Keterbatasan utama dari pendekatan unimodal adalah kurangnya kemampuan dalam menangkap anomali halus yang ditinggalkan oleh proses generatif. Model berbasis domain piksel (RGB) cenderung fokus pada pola spasial dan tekstur, namun gagal dalam mendeteksi artefak statistik frekuensi tinggi yang dihasilkan dari proses sintesis. Oleh karena itu, dibutuhkan sistem yang mampu memanfaatkan lebih dari satu jenis informasi baik dari domain spasial, frekuensi, maupun kompresi.

Untuk menjawab tantangan tersebut, penelitian ini mengusulkan sistem deteksi keaslian citra digital berbasis *Convolutional Neural Network* (CNN) dengan pendekatan multi-modal. Pendekatan ini menggabungkan tiga jalur input yang saling melengkapi: (1) citra asli dari domain spasial untuk menganalisis warna, tekstur, dan komposisi visual; (2) *Error Level Analysis* (ELA) untuk mendeteksi perbedaan tingkat kompresi yang dapat mengindikasikan modifikasi sehingga keaslian citra digital dapat dikenal[8], dan (3) *Residual Noise Map* (RDM) untuk menangkap pola derau periodik halus yang susah diakses oleh mata manusia, ini bisa menjadi informasi untuk analisis forensik[9].

Selain kontribusi arsitektural, penelitian ini menerapkan kerangka kerja Agile-XP dalam pengembangan model. Pada penerapan XP menawarkan percepatan dalam mengerjakan proyek dan berulang pada bagian yang ingin kita capai[10]. Penelitian ini berfokus pada tiga tujuan utama yaitu merancang arsitektur CNN multi-modal yang mampu memproses dan mengintegrasikan ketiga jenis input forensik. Mengimplementasikan metode ekstraksi fitur berbasis ELA dan RDM sebagai input komplementer. Mengevaluasi performa sistem dengan metrik akurasi, presisi, recall, dan F1-score serta membandingkannya dengan pendekatan unimodal sebagai tolak ukur kinerja.

Dengan adanya permasalahan dan tujuan diatas maka kami membuat sebuah sistem pendeteksi citra dan manusia dengan pendekatan multi-modal diharapkan mampu menjawab permasalahan dan menjadi acuan untuk penelitian selanjutnya dalam mengembangkan sebuah machine learning.

METODE



Gambar 1. Agile XP (extreme programming)

Gambar 1 menunjukkan metode pengembangan perangkat lunak yang menjadi acuan dalam pembuatan sistem deteksi citra, yaitu metode *Agile Extreme Programming (XP)*. Metode ini dipilih karena kelebihan dalam aspek teknis dan efisiensi waktu yang singkat, serta sangat sesuai dengan fokus tujuan[10].

2.1 Planning

Pada tahap ini, peneliti menetapkan tujuan utama yaitu membangun sistem yang mampu membedakan citra human dan hasil generatif (seperti DALL-E, Midjourney, dll). Ditentukan kebutuhan data minimal 2.000 gambar, terdiri dari hasil generatif dan citra human. Selain itu, dirancang juga arsitektur model dengan fitur forensik yang relevan seperti Error Level Analysis (ELA) dan Residual Noise Map (RDM).

2.2 Design

Tahap ini dilakukan secara bertahap, dimulai dari pembuatan pipeline data (hash-based duplicate check, resize menjadi 224×224, augmentasi data). Feature engineering untuk ELA dilakukan melalui proses recompresi JPEG 90%, sedangkan RDM diekstraksi menggunakan high-pass filter berbasis Gaussian blur. Selanjutnya, arsitektur multi-stream dengan backbone VGG16 dirancang untuk menerima tiga input berbeda (citra asli, ELA, RDM). Perancangan website interaktif juga dilakukan agar user bisa menguji citra secara praktis, termasuk desain interaksi frontend-backend serta usecase diagram sistem.

2.3 Coding

Pada tahap ini peneliti mengimplementasikan pipeline sesuai desain, meliputi preprocessing data, development model baseline, lalu membangun model multi-modal dengan input ELA dan RDM. Model dilatih menggunakan algoritma Adam dengan *learning rate* 1e-4, batch size 32, dan dropout 0.5 untuk regularisasi. Setelah training selesai, model diintegrasikan ke dalam aplikasi web sehingga user dapat melakukan inferensi citra dengan interface yang informatif dan real-time.

2.4 Testing

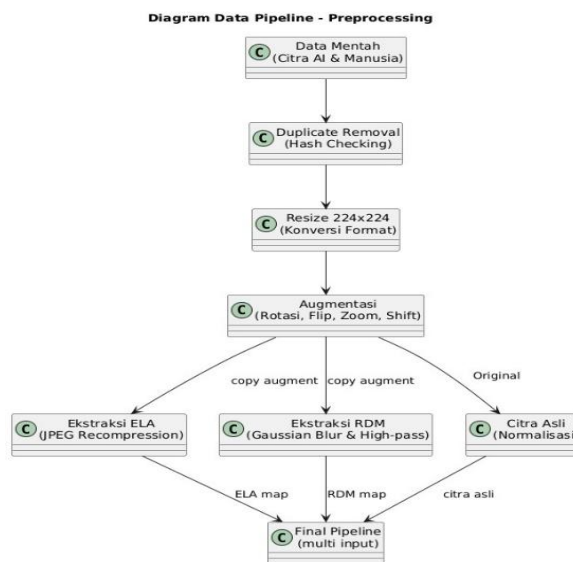
Tahap pengujian meliputi validasi data preprocessing, model akhir (multi-modal). Pengujian melibatkan pengukuran akurasi validasi, macro F1-score, serta analisis overfitting berdasarkan learning curve. Testing juga mencakup pengujian langsung pada website untuk memastikan sistem berjalan optimal di sisi frontend dan backend.

HASIL DAN PEMBAHASAN

3.1 Planning

Sesuai hasil planning, telah dikumpulkan dataset sebanyak 2.102 citra, yang terdiri dari 1.051 citra hasil generative dan 1.051 citra hasil manusia. Untuk membedakan citra hasil AI dan manusia, sistem akan menggunakan fitur forensik, yaitu Error Level Analysis (ELA) dan Residual Noise Map (RDM), untuk mendeteksi artefak halus pada gambar. Selanjutnya dipilih arsitektur VGG16 pre-trained yang sudah terbukti andal sebagai backbone model klasifikasi.

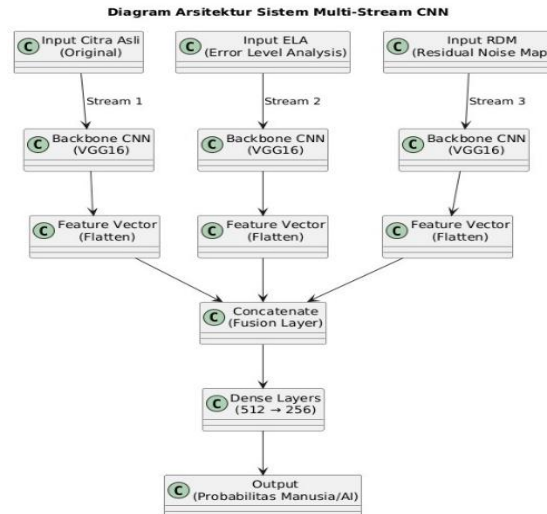
3.2 Design



Gambar 2. Diagram preprocessing data

Diagram ini menggambarkan alur persiapan data (*preprocessing*) untuk melatih model, yang dimulai dengan data mentah berupa gambar buatan AI dan human. Langkah pertama adalah duplicate removal menggunakan Hash Checking untuk membuang data identik. Selanjutnya, semua gambar distandarisasi ukurannya menjadi Resize 224x224 dan diperbanyak variasinya melalui augmentasi (seperti Rotasi, Flip, Zoom, dan Shift) untuk membuat model lebih tangguh. Langkah ini mempersiapkan satu set data yang seragam dan bervariasi untuk diproses lebih lanjut.

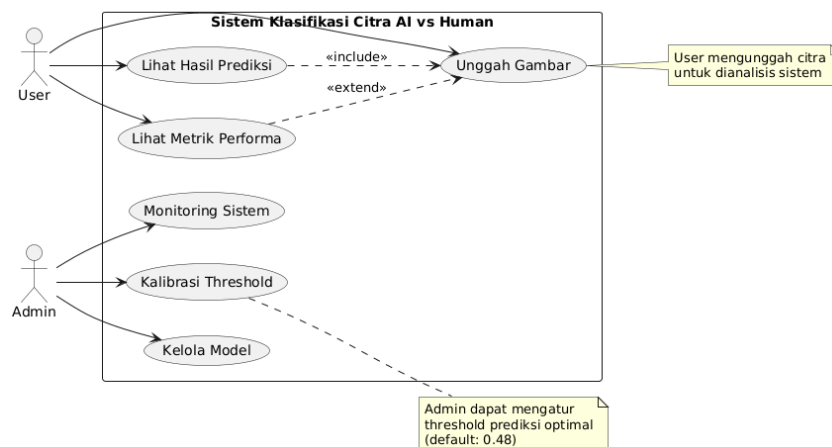
Setelah augmentasi, alur dibagi menjadi tiga jalur paralel untuk mengekstrak fitur yang berbeda. Jalur pertama melakukan ekstraksi ELA (analisis kompresi JPEG) untuk menghasilkan ELA map. Jalur kedua melakukan Ekstraksi RDM (analisis noise residual) untuk membuat RDM map. Jalur ketiga hanya menormalisasi gambar asli (Citra Asli). Akhirnya, ketiga output ini ELA map, RDM map, dan Citra asli digabungkan dalam Final Pipeline sebagai multi-input, yang memungkinkan model belajar tidak hanya dari visual gambar, tetapi juga dari artefak kompresi dan pola noise yang tersembunyi.



Gambar 3. Diagram arsitektur cnn

Diagram ini menunjukkan Arsitektur Sistem Multi-Stream CNN yang dirancang untuk menerima tiga jenis input berbeda secara bersamaan, yang merupakan hasil dari alur preprocessing sebelumnya. Sistem ini memiliki tiga jalur paralel (Stream): Stream 1 menerima Input Citra Asli, Stream 2 menerima Input ELA (Error Level Analysis), dan Stream 3 menerima Input RDM (Residual Noise Map). Setiap stream secara independen memproses inputnya menggunakan backbone VGG16, sebuah model CNN yang kuat, untuk mengekstrak fitur-fitur penting. Setelah pemrosesan oleh VGG16, output dari masing-masing stream diubah menjadi vektor satu dimensi melalui lapisan Flatten.

Setelah ketiga feature vector (satu dari citra asli, satu dari ELA, dan satu dari RDM) dibuat, ketiganya digabungkan menjadi satu vektor fitur yang komprehensif menggunakan lapisan Concatenate (Fusion Layer). Vektor gabungan ini, yang kini berisi informasi visual, artefak kompresi, dan pola noise, kemudian diteruskan ke Dense Layers (dari 512 neuron ke 256 neuron) untuk analisis dan klasifikasi tingkat lanjut. Akhirnya, jaringan menghasilkan Output berupa nilai Probabilitas, yang menentukan apakah gambar asli tersebut kemungkinan besar dibuat oleh Manusia atau oleh AI.



Gambar 4. Use Case Diagram

Pada gambar 4 ini menggambarkan fungsionalitas sistem dengan membedakan interaksi berdasarkan dua jenis aktor: User dan Admin.

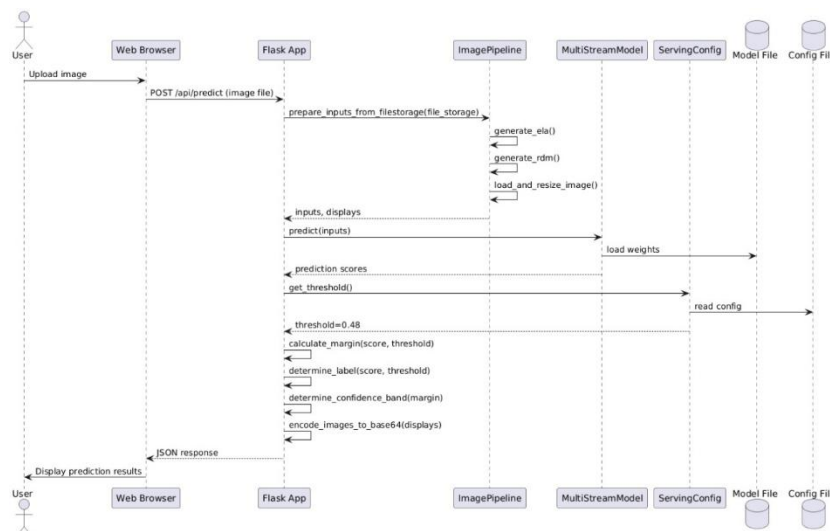
User, sebagai pengguna umum, memiliki tiga fungsi utama:

1. Unggah Gambar: User dapat mengunggah citra digital ke sistem melalui antarmuka web untuk dianalisis keasliannya (manusia atau AI).
2. Lihat Hasil Prediksi: Setelah proses inferensi selesai, user dapat melihat hasil klasifikasi berupa label (Manusia/AI), probabilitas score, confidence band (Kuat/Sedang/Tipis), serta visualisasi tiga input (citra asli, peta ELA, dan peta RDM). Use case ini memiliki relasi include dengan "Unggah Gambar", artinya hasil prediksi hanya dapat dilihat setelah gambar diunggah.
3. Lihat Metrik Performa: User dapat melihat informasi metrik evaluasi model, seperti akurasi global (91%), macro F1-score (0.91), precision dan recall per kelas (AI/Manusia), serta kurva Precision-Recall dan ROC. Use case ini bersifat extend dari "Unggah Gambar", artinya opsional dan tidak harus dilakukan setiap kali upload.

Admin, sebagai pengelola sistem, memiliki hak akses teknis yang lebih tinggi untuk pemeliharaan dan optimalisasi sistem:

1. Monitoring Sistem: Admin memantau kesehatan sistem (uptime, latency, throughput), error rate, dan performa inference real-time untuk memastikan keandalan operasional.
2. Kalibrasi Threshold: Admin dapat menyesuaikan ambang keputusan prediksi (default: 0.48) berdasarkan trade-off precision-recall yang diinginkan. Threshold ini dapat diperbarui melalui file konfigurasi (model_config.json) untuk mengoptimalkan sensitivitas deteksi AI atau mengurangi false positive.
3. Kelola Model: Admin bertanggung jawab untuk memperbarui atau mengganti model yang sedang digunakan, termasuk proses re-training dengan data baru, fine-tuning hyperparameter, atau deployment model versi terbaru ke production environment.

Diagram use case ini menunjukkan pemisahan peran yang jelas antara end-user yang berfokus pada fungsi analisis citra, dan administrator yang mengelola aspek teknis dan operasional sistem untuk menjaga performa optimal.



Gambar 5. Sequence Diagram

Diagram alur ini menjelaskan proses teknis lengkap saat User mengunggah gambar melalui Web Browser. Gambar tersebut dikirim ke Flask App (server), yang segera memerintahkan ImagePipeline untuk melakukan preprocessing (membuat input ELA, RDM, dan gambar asli). Ketiga input ini kemudian dikirim ke MultiStreamModel.

3.3 Coding

Tahapan ini merealisasikan desain dalam kode: preprocessing dan augmentasi data, membangun model baseline dengan import VGG16, serta mengimpor fungsi-fungsi seperti Dropout, Input, Flatten, Dense, dan Concatenate dari Keras/TensorFlow.

Layer (type)	Output Shape	Param #	Connected to
original_input (InputLayer)	(None, 224, 224, 3)	0	-
ela_input (InputLayer)	(None, 224, 224, 3)	0	-
rdm_input (InputLayer)	(None, 224, 224, 3)	0	-
vgg16 (functional)	(None, 7, 7, 512)	14,714,688	original_input[0], ela_input[1][0], rdm_input[2][0]
flatten (Flatten)	(None, 25088)	0	vgg16[0][0]
flatten_1 (Flatten)	(None, 25088)	0	vgg16[1][0]
flatten_2 (Flatten)	(None, 25088)	0	vgg16[2][0]
concatenate (Concatenate)	(None, 75264)	0	flatten[0][0], flatten_1[0][0], flatten_2[0][0]
dense (dense)	(None, 512)	38,535,680	concatenate[0][0]
dropout (Dropout)	(None, 512)	0	dense[0][0]
dense_1 (dense)	(None, 256)	131,328	dropout[0][0]
dropout_1 (Dropout)	(None, 256)	0	dense_1[0][0]
dense_2 (dense)	(None, 1)	257	dropout_1[0][0]

Gambar 6. Arsitektur model neural network

Model final dibangun dengan tiga input stream:

- a. original_input: Input untuk citra asli (224×224×3)
- b. ela_input: Input untuk peta ELA (224×224×3)
- c. rdm_input: Input untuk peta RDM (224×224×3)

Setiap stream melewati VGG16 pre-trained (frozen layers), kemudian output dari ketiga stream di-flatten dan di-concatenate menjadi vektor joint feature 75,264 dimensi.

Fusion dilanjutkan dengan:

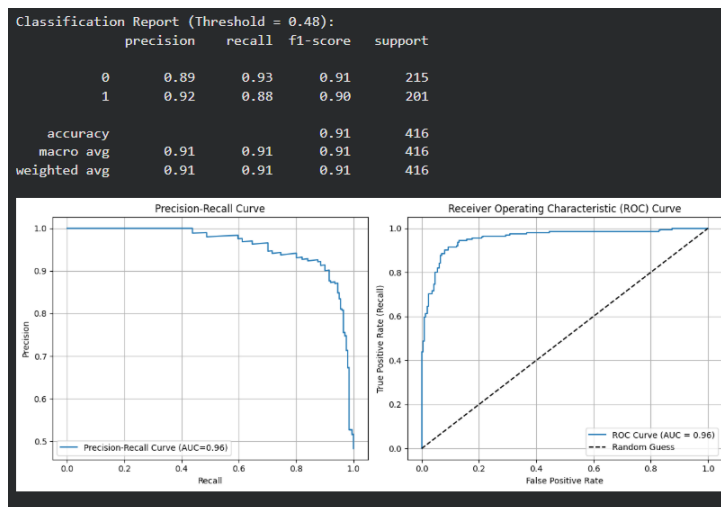
- a. Dense(512, relu) + Dropout(0.5)
- b. Dense(256, relu) + Dropout(0.5)
- c. Dense(1, sigmoid) untuk output probabilitas biner

Model dilatih menggunakan optimizer Adam dengan learning rate 1e-4, batch size 32, dan mixed precision untuk efisiensi. Regularisasi dropout 0.5 diterapkan pada dua lapisan dense untuk mencegah overfitting. Callback EarlyStopping (patience=5) dan ModelCheckpoint digunakan untuk menyimpan best model berdasarkan validation accuracy. Setelah model optimal diperoleh (mencapai validation accuracy 91% pada epoch 9/50), dilakukan integrasi ke dalam aplikasi web Flask agar user dapat melakukan analisis citra secara real-time melalui antarmuka web yang responsif dan informatif.

3.4 Testing

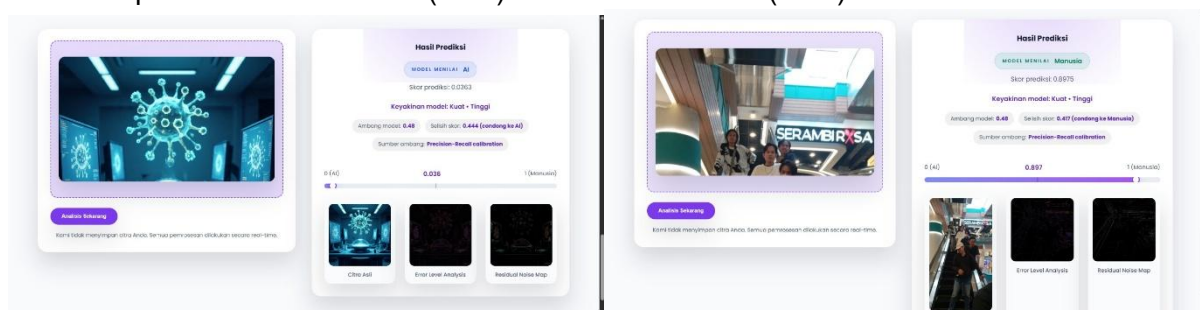
Testing dimulai dari validasi preprocessing dan pipeline data, memastikan bahwa fungsi generate_ela dan generate_rdm menghasilkan output yang konsisten tanpa NaN atau Inf values. Evaluasi model dilakukan pada:

- a. Model baseline unimodal (hanya citra asli): Mencapai akurasi ~82-85% pada validation set
- b. Model akhir multi-modal (Original + ELA + RDM): Mencapai akurasi 91% dengan macro F1-score 0.91. Metrik evaluasi yang digunakan meliputi:



Gambar 7. Hasil training

Analisis overfitting dilakukan melalui learning curve: model menunjukkan konvergensi cepat pada epoch awal dengan validation accuracy stabil di kisaran 85-91%. Training dihentikan pada epoch 14/50 oleh EarlyStopping sebelum terjadi overfitting signifikan. Kalibrasi threshold dilakukan melalui grid search pada kurva Precision-Recall, menghasilkan threshold optimal 0.48 untuk memaksimalkan macro F1-score. Threshold ini memberikan balance optimal antara recall AI (93%) dan recall manusia (88%).



Gambar 8. Hasil testing website

Pada gambar 8. adalah hasil Blackbox testing pada website dilakukan untuk memastikan fungsi berjalan sesuai harapan: Upload gambar: Support untuk JPEG, PNG, RGBA dengan drag-and-drop interface Proses inferensi: Average response time <2 detik (GPU) atau <3.5 detik (CPU) Hasil dan visualisasi: Menampilkan prediction label (/Manusia), confidence score, probability breakdown, dan tiga preview images (Original, ELA, RDM) dalam format base64 Error handling: Validasi format file, size limit (10 MB), dan error messages yang user-friendly, Testing menunjukkan success dengan berbagai format dan ukuran gambar, membuktikan robustness sistem dalam production environment.

Dengan hasil testing terhadap model dan website, peneliti melakukan perbandingan kelebihan dan performa pada penelitian ini terhadap beberapa penelitian sebelumnya, sebagaimana dirangkum pada Tabel 1.

Tabel 1. Perbandingan penelitian terkait

Penelitian	Metode	Dataset	Akurasi
Subkhi et al. (2023)	VGG19 (unimodal)	-	~100%*
Erwin et al. (2025)	DeiT Base	6.000	>95%
Penelitian ini	VGG16 Multi-modal	2.102	91%

Meskipun akurasi penelitian ini sedikit lebih rendah dibandingkan beberapa hasil di literatur, pendekatan multi-modal yang digunakan menunjukkan keunggulan pada aspek keandalan dan kemampuan generalisasi. Hasil Subkhi et al. yang melaporkan akurasi mendekati 100% mengindikasikan potensi overfitting yang tinggi sehingga validitas pada data baru diragukan. Sebaliknya, model yang dikembangkan pada penelitian ini menunjukkan akurasi validasi yang stabil di angka 91% menandakan keseimbangan antara fitting dan kemampuan generalisasi.

Keaslian citra digital tidak dapat hanya diandalkan pada analisis visual atau dengan mata saja, tetapi memerlukan integrasi teknologi forensik seperti artefak kompresi (ELA) dan residual noise (RDM) untuk mendeteksi ciri khas citra digital. Keunggulan lain dari penelitian ini adalah penentuan threshold optimal (0,48) berdasar analisis kurva Precision-Recall, serta pemanfaatan arsitektur CNN multi-modal yang terbukti lebih robust secara eksperimental.

Keterbatasan penelitian ini terletak pada ukuran serta keragaman dataset. Oleh karena itu, pengembangan sistem ke depan sangat disarankan dengan memperkaya variasi data dan mengeksplorasi arsitektur lanjutan seperti transformer multi-modal, sehingga dapat meningkatkan kehandalan dan validitas sistem dalam menghadapi tantangan di masa mendatang.

KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem klasifikasi citra berbasis CNN multi-modal untuk membedakan gambar hasil generasi AI dan gambar buatan manusia. Dengan menggabungkan tiga jenis input citra asli, peta Error Level Analysis (ELA), dan Residual Noise Map (RDM) model mampu menangkap informasi dari domain spasial, artefak kompresi, dan pola derau yang tidak dapat dideteksi oleh pendekatan unimodal.

Model berbasis VGG16 dengan arsitektur multi-stream yang dikembangkan mencapai akurasi validasi 91% dan macro F1-score 0.91, menunjukkan performa yang stabil dan kemampuan generalisasi yang baik terhadap data baru. Threshold optimal dikalibrasi pada nilai 0.48 untuk memaksimalkan keseimbangan antara recall AI (94%) dan recall manusia (88%). Hasil ini menegaskan efektivitas pendekatan multi-modal dalam meningkatkan ketepatan deteksi keaslian citra dibandingkan dengan metode unimodal sebelumnya.

Implementasi sistem berbasis web menggunakan framework Flask menunjukkan kelayakan penerapan dalam skenario dunia nyata, dengan waktu respons inferensi rata-rata di bawah 2 detik pada GPU dan di bawah 3,5 detik pada CPU, serta antarmuka yang intuitif bagi pengguna. Sistem ini berpotensi untuk dimanfaatkan dalam berbagai bidang seperti forensik digital, pengawasan hak cipta, dan deteksi disinformasi visual.

Untuk penelitian selanjutnya, disarankan untuk memperluas dataset dengan variasi sumber citra yang lebih beragam, termasuk output dari model AI generatif terbaru, serta mengeksplorasi arsitektur transformer multi-modal seperti CLIP atau Vision Transformer (ViT) untuk meningkatkan akurasi dan efisiensi komputasi. Selain itu, implementasi teknik explainable AI seperti Grad-CAM dapat ditambahkan untuk memberikan interpretasi visual terhadap keputusan model, sehingga meningkatkan transparansi dan kepercayaan pengguna terhadap sistem.

DAFTAR PUSTAKA

- [1] M. Farwati, I. Talitha Salsabila, K. Raihanun Navira, T. Sutabri, and U. Bina Darma Palembang, "Analisa pengaruh teknologi artificial intelligence (AI) dalam kehidupan sehari-hari [Analyze the influence of artificial intelligence (AI) in daily life]," *J. Sist. Inform. dan Manajemen*, vol. 11, no. 1, pp. 41–42, 2023.
- [2] S. R. Rahayu Angelika Septi and Handri, "Analysis of Fake Face Images: Detecting the Authenticity of Manipulated Images Using Variational Autoencoder Methods and Deep Neural Network Forensics," *Sibatik J. | Vol.*, vol. 2, no. 9, pp. 2701–2726, 2023, [Online]. Available: <https://publish.ojs-indonesia.com/index.php/SIBATIK>
- [3] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," *J. Informatics Comput. Sci.*, vol. 1, no. 02, pp. 104–108, 2020, doi: 10.26740/jinacs.v1n02.p104-108.
- [4] Rismiyati and A. Luthfiarta, "Klasifikasi Kualitas Buah Salak dengan Transfer Learning Arsitektur VGG16," *J. Inform. dan Teknol. Inf.*, vol. 18, no. 1, pp. 37–48, 2021, doi: 10.31515/telematika.v18i1.4025.
- [5] D. Maulana, N. S. Azzahrah, R. A. Syach, and S. Syauri, "IDENTIFIKASI KONTEN VISUAL BUATAN AI DENGAN RESNET DAN FINE-GRAINED FEATURE EXTRACTION," vol. 13, no. 3.
- [6] M. B. Subkhi, A. B. Setiawan, and M. Y. A. Candra, "Klasifikasi Gambar: Membedakan Lukisan Buatan Manusia dan AI dengan CNN," *Paradig. J. Filsafat, Sains, Teknol. dan Sos. Budaya*, vol. 29, no. 4, pp. 149–155, 2023.
- [7] A. I. Dan *et al.*, "INTI NUSA MANDIRI," vol. 19, no. 2, pp. 172–180, 2025.
- [8] A. Wicaksono, N. Mardiyantoro, and H. Sibyan, "Penerapan Metode Error Level Analysis Untuk Mendeteksi Modifikasi Citra Digital," *Biner J. Ilm. Inform. dan Komput.*, vol. 1, no. 1, pp. 62–69, 2022, doi: 10.32699/biner.v1i1.2852.
- [9] M. Gardella, P. Mus, M. Colom, and J. Morel, "Image Forgery Detection Based on Noise Inspection : Analysis and Refinement of the Noisesniffer Method," vol. 14, pp. 86–115, 2024.
- [10] R. Indra, A. Thyo, and A. Rahman, "Implementasi Metode Pengembangan Sistem Extreme Programming (XP) pada Aplikasi Investasi Peternakan Implementation of Extreme Programming (XP) System Development Method in Livestock Investment Application," pp. 272–277, 2020, doi: 10.26418/justin.v8i3.40273.