



IDENTIFIKASI OBJEK PADA CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORKS

Obi Agustian¹, Ari Syaripudin²

^{1,2} Teknik Informatika, Universitas Pamulang
Tangerang Selatan, Banten, Indonesia 15417
obi.agustian57@gmail.com, dosen00671@unpam.ac.id

Abstract

The advancement of Artificial Intelligence (AI) in generating image-based content has reached a level comparable to that of digital artists, particularly in anime-style artwork, making it increasingly difficult to identify an image's creator. However, this rapid development has not been widely accepted. Many individuals, including artists and art enthusiasts, reject AI-generated images. This often leads to debates about an image's origin or accusations that a work is AI-generated, which can escalate into conflict. This study implements an object identification technique limited to the domain of digital art to distinguish specific visual features produced by AI algorithms and human artists, resulting in a percentage likelihood for each class. This percentage can serve as a reference for evaluating an image's classification. The model is developed by fine-tuning a pre-trained ResNet50 and training it on an updated dataset. The dataset was collected from two Hugging Face repositories, "danbooru2025" and "pixiv-niji-journey," with each class containing 12,500 images. Experimental results show the model achieves 95.64% accuracy and an F1-score of 0.9570, indicating it can effectively and reliably identify both AI-generated and human-created images.

Keywords: AI-Generated Art, Anime Illustration, Artists, Binary Classification, ResNet50

Abstrak

Perkembangan *Artificial Intelligence* (AI) dalam membuat konten berupa gambar kini sudah dapat menyamai hasil karya para seniman lukis digital, terkhusus lukisan dengan *art-style anime*, sehingga suatu gambar sangat sulit untuk dibedakan siapa pembuatnya. Perkembangan yang sangat cepat ini belum dapat diterima secara umum. Banyak orang yang menolak gambar buatan AI, baik dari para seniman atau pun para penikmat seni lukis. Hal tersebut sering kali memicu perdebatan terkait asal suatu gambar, atau tuduhan bahwa suatu karya merupakan gambar buatan AI, yang berujung menjadi sebuah permasalahan. Penelitian ini mengimplementasikan teknik identifikasi objek yang terbatas hanya pada domain seni digital untuk membedakan fitur-fitur visual spesifik yang dihasilkan oleh algoritma AI dan seniman manusia, dengan hasil berupa persentase kemungkinan kelas dari gambar yang diberikan. Hasil persentase tersebut dapat digunakan sebagai bahan pertimbangan dalam menilai kelas suatu gambar. Model dibuat dengan menerapkan metode Fine-Tuning terhadap model *pre-trained* ResNet50, kemudian dilatih menggunakan *dataset* terbaru. *Dataset* berasal dari dua *repository* di Hugging Face, dengan nama *dataset* "danbooru2025" dan "pixiv-niji-journey". Setiap kelas akan dibuat memiliki 12500 sampel gambar. Pengujian terhadap model menunjukkan nilai *accuracy* mencapai 95.64% dan nilai F1-Score mencapai 0.9570. Hasil pengujian tersebut menunjukkan bahwa model dapat mengidentifikasi gambar buatan AI dan Seniman dengan seimbang dan sangat baik.

Kata kunci: Gambar Anime, Gambar Buatan AI, Klasifikasi Biner, ResNet50, Seniman

1. PENDAHULUAN

Beberapa tahun belakangan perkembangan *Artificial Intelligence* (AI) meningkat dengan sangat pesat, hal ini didukung dengan munculnya *Large Language Model* (LLM) dan *multimodal Generative Artificial Intelligence* (GAI) canggih yang menggunakan teks, audio, gambar, dan video sebagai *input* maupun *output*. Dapat dikatakan, meningkatnya perkembangan AI dimulai oleh OpenAI,

selaku perusahaan yang berfokus pada penelitian terhadap AI dan pengembangan sebuah LLM yang mereka beri nama *Generative Pre-trained Transform* (GPT). Hampir setahun setelah itu Open AI mengeluarkan sebuah model penghasil gambar berbasis *text-to-image* bernama DALL-E yang mampu menghasilkan gambar dengan tingkat *photorealism* yang tinggi. Keberhasilan OpenAI mendorong beberapa

perusahaan pengembang AI seperti: *Claude*, *Midjourney inc.*, dan *Stability AI* [1], [2], [3], [4], [5].

Saat ini, teknologi AI semakin populer dan banyak digunakan baik untuk keperluan individu maupun untuk keperluan industri. Nilai pasar teknologi AI bahkan diperkirakan mencapai 48 milyar dolar Amerika Serikat. Model pembuat gambar berbasis *Generative Adversarial Network* (GAN) maupun berbasis *Stable Diffusion* (SD) sudah banyak beredar di internet dan dapat diakses oleh siapa saja. Namun di sisi lain, kemajuan ini juga menimbulkan dampak negatif yang perlu diperhatikan [6]. Sebagai contoh, dalam dunia kesenian khususnya gambar, pada tahun 2022 lalu seseorang bernama Jason M. Allen menjadi juara dalam pameran seni Colorado State Fair dengan gambar hasil AI yang dia buat menggunakan *Midjourney*. Juri-juri pameran tersebut tidak tahu bahwa *Midjourney* merupakan sebuah AI yang dapat membuat gambar hanya dengan mengetikkan deskripsi gambar atau *prompt*, lalu gambar akan selesai dalam waktu singkat. Kebenaran tentang gambar tersebut baru diketahui secara publik dan menjadi kontroversi, setelah Jason M. Allen mengunggah kemenangannya di sosial media miliknya. Banyak seniman yang tidak setuju dengan kemenangan tersebut [7]. Tidak hanya itu, ada juga kasus-kasus penyalahgunaan AI lainnya seperti penipuan, plagiarisme konsep gambar, penyalahgunaan ciri khas gaya lukis atau *art-style* dari seorang seniman untuk menyampaikan ujaran kebencian, rasisme yang mengarah ke genosida, pendapatan seniman menurun, dan bahkan beberapa seniman kehilangan pekerjaannya [6], [8], [9].

Maraknya penyalahgunaan serta semakin canggihnya teknologi AI dalam membuat gambar yang menyerupai aslinya, termasuk juga meniru suatu gaya lukis seorang seniman, mendorong beberapa platform sosial tempat para seniman menunjukkan hasil karyanya, contohnya Pixiv, mengeluarkan kebijakan yang berkaitan tentang pelarangan menggunakan gambar-gambar di platform tersebut untuk tujuan melatih model AI, dan juga mengharuskan para seniman yang memanfaatkan AI untuk melabeli atau memberikan keterangan bahwa gambar tersebut dibuat menggunakan AI. Beberapa komunitas gambar di Facebook juga menetapkan aturan pelarangan gambar hasil AI untuk dibagikan. Beruntungnya di sisi akademis, penelitian yang khusus membahas tentang identifikasi gambar buatan AI juga semakin banyak dilakukan. Salah satu pendekatan yang dilakukan dalam penelitian adalah mendeteksi artefak pada sebuah gambar. Artefak, dalam konteks ini, adalah sebuah anomali dalam gambar yang biasanya ada pada gambar hasil AI akibat proses dalam pembuatan gambar. Artefak membuat suatu objek di dalamnya tampak tidak sesuai atau tidak terlihat seperti seharusnya. Hal ini terkadang dapat dilihat secara langsung, dan terkadang sangat sulit sehingga dibutuhkan bantuan teknologi untuk mendeteksinya.

Convolutional Neural Networks (CNN) merupakan salah satu algoritma yang efektif dalam mengidentifikasi artefak-


artefak dalam gambar. Hal ini didukung oleh penelitian yang dilakukan oleh Epstein, dkk. [10], dengan memanfaatkan *ResNet* (arsitektur CNN), mereka berhasil mencapai akurasi mendekati 100% dalam mengidentifikasi gambar hasil AI dan gambar asli seperti foto atau *artwork*. Penelitian lainnya yang dilakukan oleh Kusuma, dkk. [11] mencapai akurasi hingga 97.2% dengan *MobileNet* dalam mengidentifikasi gambar dengan *art-style* anime buatan AI dan gambar dengan *art-style* anime yang dibuat oleh seorang seniman. Keberhasilan mereka dalam mengaplikasikan CNN untuk mengidentifikasi gambar dipengaruhi oleh: pendekatan yang digunakan untuk melakukan identifikasi, jumlah dan variasi gambar dalam *dataset*, arsitektur CNN, dan teknik *augmentation* data yang digunakan. Penelitian Epstein, dkk. [10] melakukan pendekatan yang tidak hanya terfokus pada identifikasi gambar hasil AI saja. Mereka memperdalam pendekatan deteksi hingga ke level *pixel* untuk mendeteksi artefak pada gambar yang dihasilkan dengan teknik *Inpainting*. *Dataset* yang digunakan berisi 570,221 gambar. Selanjutnya teknik *augmentation* yang digunakan terdiri dari penambahan *watermark*, *cropping*, *blurring*, dan *grayscale*, guna meningkatkan ketahanan model. Untuk penelitian yang dilakukan oleh Kusuma, dkk. [11], pendekatan yang digunakan adalah dengan melakukan teknik *Fine-Tuning* pada dua *pre-trained model* yaitu *MobileNetV2* dan *MobileNetV3*, menggunakan *dataset* berisi 1000 gambar dengan *art-style* anime yang didapat dari hasil model generatif gambar Novel AI untuk gambar buatan AI dan *website* Danbooru untuk gambar buatan seniman. Tahap akhirnya akurasi model akan dinilai kemudian dipilihlah model dengan akurasi yang paling tinggi.

Arsitektur model dan kualitas *dataset* sangat mempengaruhi performa suatu model dalam melakukan prediksi terhadap data baru. Arsitektur dari suatu model mempengaruhi proses pembelajaran terhadap suatu data. Semakin dalam jaringan atau layer dari sebuah arsitektur, maka semakin dalam pula pemahaman model terhadap data. Kualitas *dataset* dinilai dari jumlah data, variasi data, dan seberapa mewakilinya data tersebut terhadap keadaan sebenarnya di dunia nyata. *Dataset* yang berisi 1000 sampel tergolong sedikit untuk sebuah model [12], [13], [14], [15].

Penelitian oleh Kusuma, dkk. [11] telah menunjukkan potensi penggunaan CNN dengan akurasi yang tinggi. Namun, penelitian tersebut masih memiliki keterbatasan pada jumlah *dataset* yang relatif kecil (1.000 sampel) serta hanya berfokus pada satu model generatif tertentu. Selain itu, penggunaan arsitektur *MobileNet* yang lebih ringan mungkin memiliki keterbatasan dalam mengekstraksi fitur kompleks pada ilustrasi anime terbaru yang semakin canggih. Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut dengan menggunakan *dataset* yang lebih besar dan variatif (25.000 sampel) dari sumber terbaru, serta menerapkan *fine-tuning* pada arsitektur *ResNet50* yang memiliki lapisan lebih dalam guna meningkatkan ketangguhan identifikasi.

2. METODE PENELITIAN

Penelitian ini menggunakan metodologi kuantitatif karena melibatkan eksperimen yang memerlukan sebuah *dataset* yang berisikan gambar buatan AI dan gambar buatan manusia untuk mengembangkan modelnya. Setelah itu, performa model akan dievaluasi menggunakan perhitungan matematis.



Gambar 1. Metode Penelitian

Penelitian ini melibatkan beberapa tahap, sesuai dengan alur pada Gambar 1.

2.1 Studi Literatur

Di tahap ini, peneliti mempelajari tentang permasalahan yang ada melalui beberapa literatur seperti artikel, jurnal, dan buku. Dimulai dari membaca beberapa artikel terkait dampak yang ditimbulkan dari AI terhadap kerja para seniman. Kemudian membaca beberapa hasil penelitian sebelumnya, guna memahami bagaimana penyelesaian masalah untuk kasus yang melibatkan identifikasi atau klasifikasi kelas dari citra yang ada pada sebuah gambar.

2.2 Pengumpulan Data

Tahap ini berfokus pada pengumpulan data yang dibutuhkan. Data yang akan digunakan dalam penelitian ini berupa gambar dengan *art-style* anime buatan para seniman dan gambar hasil model AI. Data tersebut dapat diperoleh dari beberapa *repository* yang tersedia di *website* Hugging Face.

2.3 Data Preprocessing

Data yang diperoleh langsung dari beberapa *repository* di *website* Hugging Face adalah data mentah yang perlu diproses lebih lanjut. Pada tahap ini data akan dibersihkan sehingga hanya menyisakan data yang dapat mendukung kualitas dari model yang akan dibuat.

2.4 Pelatihan Model

Di tahap ini, model akan dilatih menggunakan data yang telah dibersihkan, kemudian menerapkan beberapa teknik augmentasi untuk meningkatkan performa model serta mencegah *overfitting*.

2.5 Evaluasi Model

Tahap terakhir, model dievaluasi menggunakan beberapa *metrics* pengukuran seperti: perbandingan *Average Training Loss* (AVL) dan *Average Validation Loss*, *Precision*, *Recall*, dan *F1-Score*. Evaluasi model bertujuan untuk menilai seberapa baik model yang telah dibuat dalam mengklasifikasi gambar [16], [17], [18].

3. HASIL DAN PEMBAHASAN

3.1 Studi Literatur


Penelitian “A review of convolutional neural networks in computer vision” [19], membahas tentang kemampuan yang dimiliki *Convolutional Neural Networks* (CNN) dalam bidang *Computer Vision*. Penelitian ini menjelaskan bahwa keunggulan CNN terletak pada fitur pembelajaran mandiri dan ekstraksi fitur dari data, seperti citra. Berbeda dengan metode *Machine Learning* (ML) tradisional yang sering kali memerlukan ekstraksi fitur manual oleh manusia, CNN punya kemampuan untuk mengenali dan menyusun informasi penting dari data secara mandiri, mulai dari detail yang paling sederhana hingga pola yang paling rumit. CNN mampu mengidentifikasi pola-pola sederhana, seperti garis dan sudut, pada *layer* awal, dan secara bertahap mempelajari pola-pola yang lebih kompleks, seperti bagian-bagian objek, hingga akhirnya dapat mengidentifikasi objek secara keseluruhan di *layer* yang lebih dalam. CNN telah memicu banyak kemajuan dalam berbagai bidang *Computer Vision* [19], [20], seperti klasifikasi citra, segmentasi semantik, deteksi objek, dan rekonstruksi resolusi citra. Manfaat terbesar dari penggunaan CNN adalah untuk menggantikan secara bertahap metode ML tradisional, karena struktur CNN yang semakin kompleks dan beragam mampu memberikan kinerja dan akurasi yang jauh lebih baik dalam tugas-tugas berbasis citra [19].

Penelitian “Online Detection of AI-Generated Images” [10], membahas permasalahan yang berkaitan dengan semakin sulitnya manusia membedakan gambar asli dengan gambar yang dihasilkan oleh *Generative Artificial Intelligence* (GAI), seiring dengan dirilisnya model-model AI baru yang terjadi secara terus-menerus dan munculnya gambar komposit yang mencakup komponen asli dan *AI-generated* melalui teknik *inpainting*. Solusi yang diusulkan peneliti

adalah dengan mempelajari kemampuan generalisasi sebuah model pendeteksi gambar hasil AI dengan melatih model pendeteksi berbasis CNN secara bertahap. Selain itu, pendekatan prediksi juga diperluas hingga ke level *pixel* untuk mendeteksi area yang telah diterapkan teknik *inpainting*. Penelitian ini menggunakan *dataset* sebanyak 570.221 gambar, yang bersumber dari 14 model AI seperti *DDPM*, *GLIDE*, *DALL-E 2*, *Stable Diffusion v1*, *Stable Diffusion v2*, *Midjourney v2* hingga *Midjourney v5*, dan *Adobe Firefly*, serta gambar asli dari *LAION-400M*. Metode yang diterapkan meliputi pelatihan bertahap CNN (*ResNet-50*) untuk mendeteksi gambar secara keseluruhan, dan penggunaan *Fully Convolutional Network* (FCN) untuk prediksi *inpainting* di level *pixel*. Hasil penelitian menunjukkan bahwa model pendeteksi yang dilatih berhasil mencapai kinerja mendekati sempurna pada model yang pernah dilihat. Kinerja generalisasi ini meningkat seiring bertambahnya model yang dimasukkan dalam pelatihan. Dalam hal prediksi hingga ke level *pixel*, deteksi *inpainting* menunjukkan akurasi yang tinggi, dan penggunaan *CutMix augmentation* secara signifikan meningkatkan akurasi ketika sampel *inpainting* tidak tersedia. Meskipun demikian, kinerja menurun secara perlahan ketika model AI baru memiliki perubahan arsitektur yang besar [10].

3.2 Pengumpulan Data

Dataset untuk gambar dengan *art-style* anime buatan AI berasal dari repository milik pengguna dengan *username* “Linaqruf”, dengan nama *dataset* “pixiv-niji-journey”. *Dataset* dapat di-download secara langsung dari repository-nya dalam bentuk *zip*. Ukuran *file* mencapai 19.3 GiB. *Dataset* ini berisi 9768 sampel gambar dengan format *JPG* dan *PNG*, *metadata* dari gambar dalam format *JSON*, keterangan kategori gambar dalam bentuk *plain text*, dan *prompt* untuk membuat gambar tersebut. Beberapa sampel gambar dapat dilihat pada Gambar 2.



Gambar 2. Sampel dari *Dataset* pixiv-niji-journey

Sayangnya jumlah sampel kurang 2732, karena itu tambahan sampel gambar diperlukan dari sumber yang lain. Untuk sampel gambar tambahan berasal dari repository milik pengguna yang memiliki *username* “trojblue”, dengan *dataset*-nya yang diberi nama “danbooru2025-metadata”. Ada 43 *file dataset* berformat *PARQUET* yang dapat di-download secara langsung dari repository-nya. *Dataset* ini hanya memuat *metadata* yang disajikan dalam bentuk tabular. Setiap *file parquet* memiliki data sebanyak 211936 dengan beberapa *cell* yang *null* atau kosong, sehingga *dataset* yang berasal dari repository “danbooru2025-metadata” perlu untuk difilter terlebih dahulu. *Dataset*

untuk gambar dengan *art-style* anime buatan seniman didapat dari repository milik “trojblue”, dengan nama *dataset* “danbooru2025-metadata”, *dataset* yang sama untuk menambah sampel gambar buatan model AI. Selain memuat link untuk gambar anime buatan model AI, *dataset* ini juga memuat gambar anime buatan seniman.

3.3 Data Preprocessing

Dataset telah terkumpul, namun *dataset* tersebut belum dapat digunakan secara langsung. Pemeriksaan lebih lanjut diperlukan untuk memastikan bahwa semua sampel gambar yang berhasil diunduh telah memenuhi kriteria yang dibutuhkan [21]. Selama pemeriksaan *dataset*, peneliti menemukan banyak gambar yang tidak memenuhi kriteria. Sampel tersebut akan dibersihkan dengan cara dihapus dari *dataset*, sehingga hanya menyisakan sampel yang diperlukan. Dalam *dataset* gambar buatan model AI, ditemukan 3041 gambar yang tidak memenuhi kriteria. Sampel dapat di lihat pada Gambar 3.



Gambar 3. Contoh Gambar dengan kelas AI yang Tidak Memenuhi Kriteria


Sementara untuk *dataset* gambar buatan seniman, ditemukan sebanyak 2576 gambar tidak memenuhi kriteria. Sampel gambar tersebut dapat dilihat pada Gambar 4 di bawah ini.



Gambar 4. Contoh Gambar dengan kelas Seniman yang Tidak Memenuhi Kriteria

Akibat dari proses pemeriksaan dan pembersihan, kini *dataset* memiliki jumlah sampel yang tidak seimbang. Perbandingan jumlah sampel pada kedua *dataset* divisualisasikan dalam Gambar 5, diagram *pie* berikut:


Gambar Seniman vs AI [19383]



Gambar 5. Perbandingan Jumlah Sampel Setelah Pembersihan

Langkah yang peneliti ambil untuk menyeimbangkan jumlah sampel pada kedua *dataset* adalah dengan *download* gambar baru untuk masing-masing kelas, sambil memeriksa kriteria yang dimiliki gambar baru tersebut, sehingga jumlahnya sampelnya seimbang [22]. Hasilnya dapat dilihat pada Gambar 6 di bawah ini.

Gambar Seniman vs AI [25000]




Gambar 6. Perbandingan Hasil Akhir untuk *Dataset*

3.4 Pelatihan Model

Pelatihan model dilakukan di Google Colab. Sebelum itu, setiap sampel gambar pada *dataset* perlu diubah terlebih dahulu, sebelum akhirnya di-*upload* ke Google Drive dalam bentuk *zip*. Ukuran dimensi terbesar setiap gambar diubah menjadi 512 *px*. Gambar dengan ukuran yang besar membuat beban komputasi menjadi semakin besar, waktu komputasi menjadi semakin lama, dan pemborosan terhadap sumber daya memori.

Dataset yang telah di-*upload* ke Google Drive dapat dimuat secara langsung di Google Colab setelah *dataset* tersebut diekstraksi. *Dataset* kemudian dibagi menjadi tiga, yaitu: data untuk pelatihan sebanyak 80%, data untuk validasi sebanyak 10%, dan data untuk pengujian sebanyak 10%. Model *pre-trained ResNet50* [23] yang digunakan sudah tersedia melalui *library PyTorch* [24], [25], sehingga dapat langsung digunakan. *Fine-Tuning* dilakukan dengan cara membuat *module* “*torch.nn.Linear*” baru dengan total *output layer* berjumlah dua. *Module* tersebut digunakan untuk menggantikan bagian *layer* “*fc*” pada model *pre-trained*. Setelahnya, hampir setiap parameter pada model *pre-trained* dibekukan, kecuali parameter untuk *layer* “*layer4*” dan *layer* “*fc*”. *Optimizer* yang digunakan adalah *Adam* yang memiliki pengaturan *learning-rate* awal untuk *layer* “*layer4*” sebesar $1e-3$, sementara *learning-rate* awal untuk *layer* “*fc*” diatur sebesar $1e-2$. *Learning-rate* disesuaikan secara manual jika didapati nilai AVL lebih besar dari nilai ATL dan memiliki selisih yang besar, selama proses pelatihan.




Gambar 7. Grafik Perbandingan *Average Training Loss* dan *Average Validation Loss* selama 21 *Epoch*

Dapat dilihat pada Gambar 7, hasil pelatihan model dengan *epoch* sebanyak 21 kali, menunjukkan *loss* dengan nilai yang cukup rendah. AVL mencapai 10.8759% dan ATL 19.1786%. Hal tersebut menandakan bahwa model memiliki performa yang baik. Model sempat mengalami *overfitting* pada *epoch* ke-4 sampai ke-9. Namun pada *epoch* ke-10, performa model kembali stabil dengan turunnya nilai AVL. Model mulai mengalami perubahan performa yang sangat kecil setelah *epoch* ke-13. Karena itu peneliti menghentikan proses pelatihan pada *epoch* ke-21.

3.5 Evaluasi

Pengujian dilakukan dengan menggunakan 2500 sampel yang belum pernah model lihat, model berhasil memperoleh performa yang baik. Nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* tergolong tinggi. Berikut *Confusion Matrik* untuk melihat kualitasnya.



Gambar 8. *Confusion Matrix* dari Hasil Pengujian

Dapat dilihat pada Gambar 8 di atas bahwa kemampuan model dalam mengidentifikasi gambar dengan kelas AI sedikit lebih baik dibandingkan dalam mengidentifikasi gambar dengan kelas seniman. Untuk nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang didapat setelah pengujian, diperoleh dilihat pada Tabel 1 berikut.

Tabel 1. Rangkuman Performa Model dari Hasil Pengujian

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
AI	0.9536	0.9604	0.9570
Seniman	0.9593	0.9523	0.9558
<i>Accuracy</i>	0.9564		

4. KESIMPULAN

Berdasarkan hasil penelitian terhadap penggunaan model klasifikasi biner dengan arsitektur *ResNet50* untuk mengidentifikasi citra anime pada gambar buatan seniman dan buatan AI, maka didapatkan kesimpulan bahwa pelatihan model dengan menerapkan metode *Fine-Tuning* pada model *pre-trained ResNet50*, dan penggunaan *dataset* terbaru mampu membuat model belajar dengan baik hingga mencapai AVL dan ATL yang rendah. Nilai AVL yang diperoleh adalah 10.8759%, sementara ATL yang diperoleh adalah 19.1786%, dalam 21 kali *epoch*. Gambar dengan *art-style* anime buatan seniman dan gambar dengan *art-style* anime buatan AI dapat dibedakan oleh model dengan baik. Nilai *accuracy* mencapai 95.64%. Nilai *F1-Score* dalam mengidentifikasi kelas AI mencapai 0.9570 dan untuk kelas Seniman mencapai 0.9558. Selisih yang kecil antar *F1-Score* kedua kelas tersebut menunjukkan bahwa model memiliki kemampuan yang seimbang dalam membedakan gambar dengan kelas AI dan kelas Seniman.

Ucapan Terima Kasih

Penulis menyampaikan ucapan terima kasih kepada seluruh staf dan jajaran sivitas akademik Universitas Pamulang, atas dedikasi, bimbingan, serta kemudahan administrasi yang diberikan selama proses penyelesaian studi ini. Penulis juga mengucapkan terima kasih kepada rekan-rekan sepejuangan atas saran dan dukungan yang membangun dalam menyelesaikan karya ilmiah ini.

DAFTAR PUSTAKA

- [1] Y. Hong and J. Zhang, "WildFake: A Large-scale Challenging Dataset for AI-Generated Images Detection," *arXiv preprint arXiv:2402.11843*, Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.11843>
- [2] K. Sudhakar, R. Vadivel, S. Sarumathi, and S. Manjunatha, *Intelligent Systems: Bridging Machine Learning, Deep Learning and Natural Language Processing*. Leilani Katie Publication, 2024. Accessed: Feb. 24, 2026. [Online]. Available: <https://books.google.co.id/books?id=jLU6EQAAQBAJ>
- [3] K. Sharifani and M. Amini, "Machine learning and deep learning: A review of methods and applications," *World Information Technology and Engineering Journal*, vol. 10, no. 07, pp. 3897–3904, 2023, Accessed: Feb. 24, 2026. [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4458723
- [4] N. Anantrasirichai, F. Zhang, and D. Bull, "Advances in artificial intelligence: a review for the creative industries," *Artif. Intell. Rev.*, vol. 59, no. 3, p. 89, 2026, doi: 10.1007/s10462-026-11494-w.
- [5] I. D. Mienye and T. G. Swart, "A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications," *Information (Switzerland)*, vol. 15, no. 12, Dec. 2024, doi: 10.3390/info15120755.
- [6] H. H. Jiang *et al.*, "AI Art and its Impact on Artists," in *AIES 2023: Proceedings of the 2023 AAAI/ACM Conference on AI, Ethics, and Society*, Association for Computing Machinery, Inc, Aug. 2023, pp. 363–374. doi: 10.1145/3600211.3604681.
- [7] K. Roose, "AI-Generated Art Won a Prize. Artists Aren't Happy.-The New York Times," *The New York Times*, Sep. 2, 2022.
- [8] C. Zhu, X. Zhang, Y. Sun, C.-C. Chang, and I. Echizen, "AnimeDL-2M: Million-Scale AI-Generated Anime Image Detection and Localization in Diffusion Era," in *Proceedings of the 1st on Deepfake Forensics Workshop: Detection, Attribution, Recognition, and Adversarial Challenges in the Era of AI-Generated Media*, in DFF '25. New York, NY, USA: Association for Computing Machinery, 2025, pp. 45–54. doi: 10.1145/3746265.3759666.
- [9] S. Yan *et al.*, "A Sanity Check for AI-generated Image Detection," *arXiv preprint arXiv:2406.19435*, Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2406.19435>
- [10] D. C. Epstein, I. Jain, O. Wang, and R. Zhang, "Online Detection of AI-Generated Images," *arXiv preprint arXiv:2310.15150*, Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.15150>
- [11] S. W. Kusuma, F. Natalia, C. S. Ko, and S. Sudirman, "Detection of AI-generated anime images using deep learning," *ICIC Express Letters, Part B: Applications*, vol. 15, no. 3, pp. 295–301, Mar. 2024, doi: 10.24507/iciclb.15.03.295.
- [12] Z. Wang *et al.*, "A Comprehensive Survey on Data Augmentation," *arXiv preprint arXiv:2405.09591*, Oct. 2025, [Online]. Available: <http://arxiv.org/abs/2405.09591>
- [13] S. Fabbrizzi, S. Papadopoulos, E. Ntoutsis, and I. Kompatsiaris, "A Survey on Bias in Visual Datasets," *arXiv preprint arXiv:2107.07919*, Jun. 2022, [Online]. Available: <http://arxiv.org/abs/2107.07919>
- [14] U. Michelucci and F. Venturini, "Best Practices for Machine Learning Experimentation in Scientific Applications," *arXiv preprint arXiv:2511.21354*, Nov. 2025, [Online]. Available: <http://arxiv.org/abs/2511.21354>

- [15] C. Hastings Blow, L. Qian, C. Gibson, P. Obiomon, and X. Dong, "Data augmentation via diffusion model to enhance AI fairness," *Front. Artif. Intell.*, vol. 8, 2025, doi: 10.3389/frai.2025.1530397.
- [16] I. Werdiningsih, D. C. R. Novitasari, and D. Z. Haq, *Pengelolaan Data Mining dengan Pemrograman Matlab*. Airlangga University Press, 2022. Accessed: Feb. 24, 2026. [Online]. Available: <https://books.google.co.id/books?id=CgOdEAAAQBAJ>
- [17] D. Chicco and G. Jurman, "The ABC recommendations for validation of supervised machine learning results in biomedical sciences," *Front. Big Data*, vol. 5, 2022, doi: 10.3389/fdata.2022.979465.
- [18] J. Camacho, "A Set of Rules for Model Validation," *J. Chemom.*, vol. 40, no. 2, 2026, doi: 10.1002/cem.70110.
- [19] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artif. Intell. Rev.*, vol. 57, no. 4, Apr. 2024, doi: 10.1007/s10462-024-10721-6.
- [20] M. Miceli, T. Yang, L. Naudts, M. Schuessler, D. Serbanescu, and A. Hanna, "Documenting computer vision datasets: An invitation to reflexive data practices," in *FACCT 2021 - Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*. New York, NY, USA: Association for Computing Machinery, Inc, Mar. 2021, pp. 161–172. doi: 10.1145/3442188.3445880.
- [21] R. Jafari, *Hands-On Data Preprocessing in Python: Learn how to effectively prepare data for successful data analytics*. Packt Publishing, 2022. Accessed: Feb. 24, 2026. [Online]. Available: <https://books.google.co.id/books?id=H6lVEAAQBAJ>
- [22] A. Stando, M. Cavus, and P. Biecek, "The Effect of Balancing Methods on Model Behavior in Imbalanced Classification Problems," *arXiv preprint arXiv:2307.00157*, Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2307.00157>
- [23] B. Mandal, A. Okeukwu, and Y. Theis, "Masked Face Recognition using ResNet-50," *arXiv preprint arXiv:2104.08997*, Apr. 2021, [Online]. Available: <http://arxiv.org/abs/2104.08997>
- [24] A. Paszke *et al.*, "PyTorch: An Imperative Style, High-Performance Deep Learning Library," *arXiv preprint arXiv:1912.01703*, Dec. 2019, [Online]. Available: <http://arxiv.org/abs/1912.01703>
- [25] J. Ansel *et al.*, "PyTorch 2: Faster Machine Learning Through Dynamic Python Bytecode Transformation and Graph Compilation," in *Proceedings of the 29th ACM International Conference on Architectural Support for Programming Languages and Operating Systems*, Vol. 2. New York, NY, USA: Association for Computing Machinery, Apr. 2024, pp. 929–947. doi: 10.1145/3620665.3640366.