

Analisis Pengaruh Resolusi Citra pada Arsitektur EfficientNetB0 untuk Deteksi AI-Generated Portrait

^{1*}R. Muhammad Wachyu Fajar Sidik, ²Umi Mahdiyah, ³Wahyu Cahyo Utomo

^{1, 2, 3} Teknik Informatika, Universitas Nusantara PGRI Kediri
E-mail: ¹r.muhammadwachyu@gmail.com, ²umimahdiyah@gmail.com,
³wahyu.utomo@unpkdr.ac.id

Penulis Korespondens : R. Muhammad Wachyu Fajar Sidik

Abstrak — Perkembangan teknologi kecerdasan buatan dalam menciptakan potret manusia sintesis memicu risiko manipulasi informasi digital yang signifikan. Penelitian ini bertujuan untuk mengimplementasikan sistem deteksi AI-generated portrait berbasis Deep Learning dengan memanfaatkan arsitektur EfficientNetB0 dan pendekatan Transfer Learning. Fokus utama penelitian ini adalah melakukan studi ablasi untuk menganalisis ketahanan (robustness) model terhadap pengaruh variasi resolusi spasial citra masukan dengan menggunakan algoritma optimasi AdamW (Adam with Weight Decay). Eksperimen komparatif dilakukan melalui tiga skenario pengujian, yaitu resolusi standar 224×224 piksel, peningkatan resolusi (upscaling) menjadi 256×256 piksel, serta penurunan resolusi (downscaling) menjadi 192×192 piksel. Hasil penelitian menunjukkan bahwa penggunaan resolusi standar 224×224 piksel merupakan konfigurasi paling optimal dengan akurasi tertinggi sebesar 88% serta efisiensi komputasi waktu pelatihan tercepat, yakni 37 menit 12 detik. Sebaliknya, modifikasi resolusi baik upscaling maupun downscaling terbukti menyebabkan degradasi performa model dan peningkatan beban komputasi. Temuan ini menegaskan bahwa resolusi standar bawaan arsitektur merupakan titik keseimbangan (sweet spot) yang paling tepat untuk mengekstraksi elemen kontekstual potret secara akurat dan menjaga stabilitas model terhadap kerentanan noise spasial.

Kata Kunci— AI-generated portrait, EfficientNetB0, Transfer Learning, studi ablasi, AdamW, resolusi citra.

Abstract— The rapid development of artificial intelligence in creating synthetic human portraits has triggered significant risks of digital information manipulation. This study aims to implement an AI-generated portrait detection system based on Deep Learning using the EfficientNetB0 architecture and a Transfer Learning approach. The primary focus of this research is to conduct an ablation study to analyze the model's robustness against varying spatial resolutions of input images using the AdamW (Adam with Weight Decay) optimization algorithm. Comparative experiments were conducted through three test scenarios: standard 224×224 pixel resolution, upscaling to 256×256 pixels, and downscaling to 192×192 pixels. The results demonstrate that the use of standard 224×224 pixel resolution is the most optimal configuration, achieving the highest accuracy of 88% and the most efficient training time of 37 minutes and 12 seconds. Conversely, modifying the resolution both upscaling and downscaling proved to cause model performance degradation and increased computational load. These findings confirm that the architecture's native resolution serves as the sweet spot for accurately extracting portrait contextual elements while maintaining model stability against spatial noise vulnerability.

Keywords— AI-generated portrait, EfficientNetB0, Transfer Learning, ablation study, AdamW, image resolution.

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Kemajuan teknologi kecerdasan buatan (*Artificial Intelligence*) dalam beberapa tahun terakhir telah mendorong lahirnya generator citra yang mampu merender potret manusia sintesis dengan tingkat realisme yang sangat tinggi [1]. Kemampuan mesin dalam memproduksi gambar yang menyerupai manusia asli ini memicu ancaman serius berupa pemalsuan identitas digital, penyebaran berita bohong (*hoax*), serta manipulasi bukti visual di ranah hukum [2]. Oleh karena itu, pengembangan sistem komputasi yang mampu membedakan antara potret manusia alami dan potret buatan mesin secara cepat dan akurat menjadi kebutuhan yang sangat krusial.

Dalam mendeteksi manipulasi citra, analisis forensik visual tidak cukup jika hanya difokuskan pada area wajah secara terisolasi, melainkan harus menganalisis keseluruhan "potret" untuk mengevaluasi elemen kontekstual seperti anomali pencahayaan dan struktur latar belakang. *Generator AI* sering kali meninggalkan cacat struktural atau artifak mikroskopis pada area transisi antara subjek manusia dan lingkungan sekitarnya, yang menjadi kunci penting dalam klasifikasi keaslian sebuah gambar.

Penelitian terdahulu di bidang visi komputer (*Computer Vision*) telah banyak mengeksplorasi penggunaan arsitektur jaringan saraf tiruan konvolusional (*Convolutional Neural Network*) untuk kebutuhan klasifikasi biner, salah satunya menggunakan arsitektur EfficientNetB0 yang terbukti efisien dan akurat karena mengandalkan metode penskalaan terstruktur (*Compound Scaling*) [3]. Pendekatan *Transfer Learning* menggunakan arsitektur ini efektif untuk mengenali pola-pola anomali pada gambar tanpa memerlukan sumber daya komputasi yang masif.

Namun, tantangan terbesar dalam deteksi citra sintesis di dunia nyata saat ini adalah masalah pergeseran domain (*domain shift*) di mana performa model pengklasifikasi sering kali mengalami degradasi drastis ketika dihadapkan pada foto tangkapan kamera ponsel pintar modern [4]. Kamera gawai secara terintegrasi menerapkan teknologi Computational Photography melalui komponen *Image Signal Processor* (ISP) bawaan untuk melakukan manipulasi instan seperti reduksi noise dan penghalusan kulit (*skin smoothing*), yang pada prosesnya menyapu bersih detail artifak frekuensi tinggi penentu algoritma dalam mengenali keaslian gambar [5].

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan arsitektur deteksi *AI-generated portrait* berbasis EfficientNetB0 dengan pendekatan *transfer learning*. Fokus utama penelitian ini adalah melakukan analisis studi ablasi terhadap pengaruh variasi resolusi dimensi citra yang dilatih secara khusus menggunakan fungsi optimasi AdamW [6], guna menemukan dimensi spasial yang optimal dalam mengekstraksi elemen kontekstual potret secara utuh dan meminimalkan kerentanan model terhadap pergeseran domain (*domain shift*) [7].

II. METODE

Penelitian ini menggunakan metode eksperimental komputasi untuk mengevaluasi performa dan stabilitas model *Deep Learning* dalam mengklasifikasikan keaslian citra. Alur kerja disusun secara terstruktur meliputi tahap pengumpulan citra, prapemrosesan data statis, pembagian data, pelatihan model dengan *transfer learning*, hingga evaluasi performa metrik klasifikasi.

A. Subjek, Bahan, dan Alat Penelitian

Bahan utama dalam eksperimen komputasi ini adalah data citra potret manusia yang dibagi ke dalam dua kelas target, yaitu potret manusia asli (ASLI) dan potret hasil generasi kecerdasan buatan (AI). Fokus objek secara konsisten dipertahankan pada lingkup keseluruhan "potret" guna memastikan model dapat menangkap elemen kontekstual di luar wajah, seperti struktur pencahayaan dan latar belakang. Alat komputasi yang dioperasikan mencakup bahasa pemrograman Python 3.11, pustaka TensorFlow/Keras untuk perancangan arsitektur *Deep Learning*, serta pustaka OpenCV untuk kebutuhan prapemrosesan dan manipulasi matriks citra [8].

B. Variabel Penelitian

Pengklasifikasian variabel dalam eksperimen ini disusun dengan menempatkan data citra potret sebagai kategori data statis (bukan variabel independen), sedangkan label status keaslian citra (AI atau ASLI) diukur sebagai variabel dependen.

C. Rancangan Percobaan dan Evaluasi Model

Desain eksperimen komputasi difokuskan pada studi ablasi untuk mengevaluasi pengaruh variasi skala resolusi spasial terhadap performa arsitektur *Deep Learning* EfficientNetB0 menggunakan fungsi optimasi konstan. Pengujian dibagi ke dalam tiga skenario komparatif yang seluruhnya dilatih menggunakan algoritma optimasi AdamW (*Adam with Weight Decay*). Skenario pengujian meliputi resolusi standar 224×224 piksel (Skenario 1), peningkatan resolusi atau upscaling ke 256×256 piksel (Skenario 2), dan penurunan resolusi atau downscaling ke 192×192 piksel (Skenario 3). Kinerja ekstraksi fitur model dari masing-masing resolusi dievaluasi secara statistik menggunakan instrumen *Confusion Matrix* guna mendapatkan nilai parameter ukur berupa Akurasi, Presisi, *Recall*, dan *F1-Score*.

D. Prosedur Penelitian Lengkap



Gambar 1. Diagram Alir Proses Penelitian

Agar seluruh rangkaian eksperimen dalam penelitian ini dapat direproduksi secara komprehensif oleh peneliti independen, tahapan penelitian dieksekusi secara sistematis sesuai dengan alur berikut:

1. Pengumpulan Citra

Mengumpulkan himpunan data citra potret manusia yang terbagi secara seimbang ke dalam kelas potret manusia asli dan potret buatan generator AI.

2. Prapemrosesan Data Statis

Prapemrosesan Data Statis: Melakukan tahapan pengolahan awal pada citra mentah yang mencakup proses normalisasi piksel dan penyesuaian resolusi spasial matriks citra. Dimensi gambar diubah ukurannya secara presisi agar sesuai dengan kebutuhan resolusi masing-masing skenario eksperimen (224×224 , 256×256 , atau 192×192 piksel).

3. Pembagian Data

Tabel 1. Distribusi Pembagian Dataset

Kategori Data	Persentase	Jumlah Citra
Data Pelatihan (<i>Training Set</i>)	70%	1.025
Data Validasi (<i>Validation Set</i>)	15%	220
Data Pengujian (<i>Testing Set</i>)	15%	219
Total	100%	1.464

Total dataset sebanyak 1.464 citra potret manusia dibagi secara proporsional untuk memastikan model memiliki volume data latih yang memadai serta data validasi dan pengujian yang representatif untuk mengukur kinerja model secara objektif

4. Pelatihan Model (*Transfer Learning*)

Penelitian ini menggunakan pendekatan *Transfer Learning* pada arsitektur EfficientNetB0 yang telah dilatih sebelumnya (*pre-trained*) untuk mengenali fitur visual dasar secara efisien.

- a. Pembekuan Bobot: Bobot dasar (*base weights*) pada lapisan ekstraksi fitur dibekukan untuk mempertahankan representasi fitur yang sudah dipelajari, sehingga proses pelatihan menjadi lebih efisien.
- b. Lapisan Klasifikasi: Lapisan klasifikasi baru ditambahkan setelah lapisan ekstraksi fitur, menggunakan *Global Average Pooling* dan *Dense Layer* dengan fungsi aktivasi *Sigmoid* untuk menghasilkan probabilitas biner (kelas "AI" atau "ASLI") [9].
- c. Optimasi AdamW: Pelatihan menggunakan algoritma AdamW yang memisahkan mekanisme penalti bobot (*weight decay*) dari perhitungan gradien. Pemisahan ini memungkinkan kontrol regularisasi yang lebih presisi, sehingga efektif mencegah *overfitting* dan meningkatkan stabilitas model [10].

5. Evaluasi Performa Model

Validasi hasil klasifikasi dilakukan menggunakan *Confusion Matrix* untuk memetakan prediksi yang tepat dan rasio kesalahan model [11]. Berdasarkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), parameter performa dikalkulasikan dengan rumus berikut:

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

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

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

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

Selanjutnya, dilakukan analisis komparatif terhadap kurva riwayat pembelajaran (*loss* dan *accuracy*) guna memetakan kecepatan konvergensi serta mengidentifikasi risiko ketidakstabilan seperti gejala *overfitting* atau *catastrophic forgetting* [12].

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen komputasi terhadap pengujian arsitektur EfficientNetB0 dengan pendekatan *Transfer Learning*. Evaluasi difokuskan pada studi ablasi untuk menguji ketahanan (*robustness*) model terhadap perubahan dimensi resolusi citra masukan menggunakan algoritma optimasi AdamW (*Adam with Weight Decay*). Pengujian dilakukan untuk melihat apakah penambahan atau pengurangan detail spasial memengaruhi akurasi sistem dalam membedakan potret manusia asli dan potret *AI-generated* tanpa kehilangan konteks struktural seperti pencahayaan dan latar belakang.

A. Hasil Eksperimen dan Evaluasi Model

Eksperimen dilakukan secara sekuensial dengan membandingkan performa model pada resolusi standar arsitektur 224×224 piksel (Skenario 1) terhadap modifikasi peningkatan resolusi atau *upscaling* menjadi 256×256 piksel (Skenario 2), serta penurunan resolusi atau *downscaling* menjadi 192×192 piksel (Skenario 3). Kinerja model dievaluasi menggunakan *Confusion Matrix* untuk menghasilkan parameter ukur yang komprehensif. Rangkuman perbandingan ketiga skenario tersebut disajikan pada Tabel 1.

Tabel 2. Tabel Skenario


Skenario	Resolusi	Kelas Target	Presisi	Recall	F1-Score	Akurasi	Waktu Komputasi
1	224×224	AI	0.86	0.91	0.88	88%	37 Menit 12 Detik
		ASLI	0.90	0.84	0.87		
2	256×256	AI	0.87	0.83	0.85	85%	41 Menit 37 Detik
		ASLI	0.83	0.87	0.85		
3	192×192	AI	0.84	0.87	0.86	85%	42 Menit 16 Detik
		ASLI	0.87	0.83	0.85		

B. Pembahasan dan Analisis Skenario Pengujian

Dinamika perubahan performa dari ketiga skenario di atas menunjukkan bahwa arsitektur sistem sangat bergantung pada ketajaman resolusi. Perubahan dimensi citra, baik diperbesar maupun diperkecil dari titik tersebut, secara konsisten mengakibatkan degradasi performa model. Analisis mendalam dari masing-masing skenario dijabarkan sebagai berikut:

1. Skenario 1 Resolusi (224×224)


Skenario pertama menerapkan optimasi AdamW (*Adam with Weight Decay*) sebagai *baseline* untuk melihat kapabilitas model pada resolusi bawaan arsitektur, yaitu 224×224 piksel. Dinamika pembelajaran model AdamW divisualisasikan pada grafik berikut.



Gambar 2. Grafik Performa Training Skenario 1

Berdasarkan grafik performa di atas, terlihat tingkat stabilitas optimasi yang sangat baik. Kurva *Validation Loss* tetap stabil dan beriringan dengan *Train Loss* hingga mencapai titik optimalnya (*Best Model Checkpoint*) pada epoch ke-9. Stabilitas ini membuktikan bahwa mekanisme pada AdamW efektif mencegah model dari *overfitting* serta menjaga keandalan pembelajaran.

Setelah model mencapai titik konvergen, evaluasi akhir dilakukan pada data uji. Rincian hasil prediksi divisualisasikan pada *Confusion Matrix* berikut.




Gambar 3. Confusion Matrix Skenario 1

Berdasarkan sebaran matriks klasifikasi di atas, skenario ini membuktikan kinerja yang paling maksimal dengan capaian akurasi tertinggi sebesar 88% dan keseimbangan nilai *F1-Score* yang kuat. Penggunaan resolusi standar ini memberikan kesesuaian spasial yang paling sempurna untuk mengekstraksi fitur kompleks tanpa kehilangan konteks struktur pada potret manusia, sekaligus mencatatkan waktu pelatihan tercepat yakni 37 menit 12 detik.

2. Skenario 2 Resolusi (256×256)


Skenario kedua merupakan studi ablasi yang menguji ketahanan model dengan meningkatkan resolusi citra masukan (*upscaling*) menjadi 256×256 piksel. Dinamika pembelajaran model pada resolusi ini divisualisasikan pada grafik berikut:



Gambar 4. Grafik Performa Training Skenario 2

Berdasarkan grafik di atas, terlihat adanya ketidakstabilan pada fase *Fine-Tuning* (setelah *epoch* ke-20). Meskipun Train Accuracy sempat mencapai angka di atas 0.90, kurva *Validation Accuracy* cenderung mendatar dan tidak mampu mengikuti peningkatan performa data latih, yang mengindikasikan adanya celah *overfitting* yang lebih lebar dibandingkan resolusi standar.

Setelah model mencapai titik konvergen, evaluasi akhir dilakukan pada data uji. Rincian hasil prediksi divisualisasikan pada *Confusion Matrix* berikut.




Gambar 5. Confusion Matrix Skenario 2

Berdasarkan hasil pengujian yang terefleksi pada *Confusion Matrix*, peningkatan resolusi justru merusak kesesuaian filter konvolusi bawaan dari arsitektur EfficientNetB0. Pelebaran dimensi membuat ukuran fitur artifak pada citra menjadi lebih besar dari ukuran area reseptif (*receptive field*) filter konvolusi, menyebabkan penurunan akurasi menjadi 85% dan beban komputasi yang membengkak menjadi lebih dari 41 menit. Model gagal menangkap pola sintesis secara utuh dan menjadi lebih rentan terhadap *overfitting* serta *noise*.


3. Skenario 3 Resolusi (192×192)

Skenario ketiga menguji efek penurunan dimensi citra (*downscaling*) ke ukuran 192×192 piksel terhadap kapabilitas ekstraksi fitur model. Dinamika pembelajaran model pada resolusi ini divisualisasikan sebagai berikut:



Gambar 6. Grafik Performa Training Skenario 3

Berdasarkan grafik di atas, terlihat pola yang serupa dengan Skenario 2, di mana terjadi ketidakstabilan pada fase *Fine-Tuning* setelah epoch ke-21 yang ditandai dengan lonjakan *Train Loss* dan penurunan *Validation Accuracy* yang cukup konsisten. Penurunan skala citra ini berdampak langsung pada hilangnya informasi piksel yang krusial. Kompresi gambar menurunkan kemampuan generalisasi model sehingga akurasi tertahan di angka 85%.



Gambar 7. Confusion Matrix Skenario 3

Melalui evaluasi pada *Confusion Matrix*, terlihat bahwa model mulai menunjukkan kesulitan dalam merepresentasikan artifak manipulasi yang subtil akibat penyusutan kerapatan piksel. Model kehilangan jejak fitur mikroskopis dari potret sintesis, yang mengakibatkan performa deteksi menjadi kurang optimal. Meskipun ukuran gambar yang diproses lebih kecil, pemrosesan model justru memakan waktu lebih lama yakni mencapai 42 menit 16 detik.

IV. KESIMPULAN

Berdasarkan serangkaian eksperimen komputasi yang telah dilakukan untuk mengevaluasi pengaruh variasi resolusi citra terhadap performa arsitektur *Deep Learning* EfficientNetB0 dengan pengoptimal AdamW, didapatkan kesimpulan sebagai berikut:

1. Titik Optimal Resolusi

Arsitektur EfficientNetB0 mencapai performa deteksi paling optimal pada penggunaan resolusi standar bawaan model, yaitu 224×224 piksel. Pada konfigurasi ini, model berhasil mencatatkan tingkat akurasi tertinggi sebesar 88% dengan keseimbangan metrik *F1-Score* yang sangat baik (0.88 untuk kelas AI dan 0.87 untuk kelas ASLI).

2. Dampak Negatif *Upscaling*: Peningkatan resolusi citra secara berlebihan (*upsampling*) menjadi 256×256 piksel tidak memberikan peningkatan akurasi, melainkan justru menyebabkan degradasi performa menjadi 85%. Hal ini terjadi karena pelebaran dimensi citra melampaui kapasitas area reseptif (*receptive field*) filter konvolusi bawaan, sehingga model menjadi rentan terhadap noise spasial dan kegagalan dalam menangkap pola sintesis secara utuh.

3. Dampak Negatif *Downscaling*: Penurunan resolusi secara ekstrem (*downsampling*) menjadi 192×192 piksel mengakibatkan hilangnya informasi visual krusial. Kondisi ini menurunkan kemampuan generalisasi model sehingga akurasi tertahan pada angka 85% dan model mengalami kesulitan dalam mengidentifikasi artifak manipulasi yang subtil akibat penyusutan kerapatan piksel.

4. Efisiensi Komputasi: Penggunaan resolusi standar 224×224 piksel terbukti menjadi titik keseimbangan (*sweet spot*) yang paling efisien, di mana model mampu mencapai akurasi terbaik dengan waktu pelatihan tercepat dibandingkan variasi resolusi lainnya.

DAFTAR PUSTAKA

- [1] H. E. Nawawi, R. Rahmadewi, and L. Nulpulaela, "Pendeteksian Wajah Hasil Dari Manipulasi Ai Pada Citra Digital," *Jurnal Ilmiah Wahana Pendidikan*, vol. 10, no. 2, pp. 402–409, Jan. 2024, doi: 10.5281/ZENODO.10487513.
- [2] "Analisis Kualifikasi Hukum terhadap Penyalahgunaan Teknologi Artificial Intelligence dalam Penggunaan Citra Masyarakat | Jurnal Tana Mana." Accessed: Jun. 06, 2026. [Online]. Available: <https://ojs.staialfurqan.ac.id/jtm/article/view/1017>
- [3] C. Lin, P. Yang, Q. Wang, Z. Qiu, W. Lv, and Z. Wang, "Efficient and accurate compound scaling for convolutional neural networks," *Neural Networks*, vol. 167, pp. 787–797, Oct. 2023, doi: 10.1016/J.NEUNET.2023.08.053.
- [4] M. ABDILLAH, "RESTORASI FOTO AKIBAT KERUSAKAN DIGITAL MENGGUNAKAN DEEP LEARNING BERBASIS GENERATIVE ADVERSARIAL NETWORKS (GANs)," 2025.
- [5] M. Delbracio, D. Kelly, M. S. Brown, and P. Milanfar, "Mobile Computational Photography: A Tour," *Annu. Rev. Vis. Sci.*, vol. 7, no. Volume 7, 2021, pp. 571–604, Sep. 2021, doi: 10.1146/ANNUREV-VISION-093019-115521/CITE/REFWORKS.
- [6] "Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam | JIEET (Journal of Information Engineering and Educational Technology)." Accessed: Jun. 06, 2026. [Online]. Available: <https://journal.unesa.ac.id/index.php/jieet/article/view/15213>
- [7] E. Kondrateva, M. Pominova, E. Popova, M. Sharaev, A. Bernstein, and E. Burnaev, "Domain shift in computer vision models for MRI data analysis: an overview," <https://doi.org/10.1117/12.2587872>, vol. 11605, p. 126, Jan. 2021, doi: 10.1117/12.2587872.
- [8] "Deep Learning Dasar Teori dan Implementasi dengan Python dan Keras: Diandra ... - Prof. Darmawan Utomo, Ph. D. dan Theodora Florencia Utomo, S.Kep., M.C.S. (AI) - Google Buku." Accessed: Jun. 06, 2026. [Online]. Available: https://books.google.co.id/books?hl=id&lr=&id=nqmQEQAQBAJ&oi=fnd&pg=PA66&dq=pustaka+TensorFlow/Keras+untuk+perancangan+arsitektur+Deep+Learning&ots=JOMXLKM-dq&sig=l_ClusXtQnC8LT4j2ky7-FnNn1k&redir_esc=y#v=onepage&q&f=false
- [9] R. FATURRAHMAN, R. FATURRAHMAN, Y. S. HARIYANI, and S. HADIYOSO, "Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 4, p. 945, Oct. 2023, doi: 10.26760/elkomika.v11i4.945.
- [10] X. Wang and L. Aitchison, "How to set AdamW's weight decay as you scale model and dataset size," *Proc. Mach. Learn. Res.*, vol. 267, pp. 62222–62250, May 2024, Accessed: Jun. 06, 2026. [Online]. Available: <https://arxiv.org/pdf/2405.13698>
- [11] J. Liang, "Confusion Matrix: Machine Learning," *POGIL Activity Clearinghouse*, vol. 3, no. 4, Dec. 2022, Accessed: Jun. 06, 2026. [Online]. Available: <https://pac.pogil.org/index.php/pac/article/view/304>
- [12] Z. Xie, F. He, S. Fu, I. Sato, D. Tao, and M. Sugiyama, "Artificial Neural Variability for Deep Learning: On Overfitting, Noise Memorization, and Catastrophic Forgetting," *Neural Comput.*, vol. 33, no. 8, pp. 2163–2192, Jul. 2021, doi: 10.1162/NECO_A_01403.