

Analisis Performa Pre-Trained Model CNN pada Citra Termogram dalam Deteksi Dini Pasien Diabetes

W. Mega Adhi Agam Pradhana¹⁾, Gede Angga Pradipta^{2*)}, Roy Rudolf Huizen²⁾

Program Studi Magister Sistem Informasi
Institut Teknologi dan Bisnis STIKOM Bali
Denpasar, Indonesia

e-mail: 222012026@stikom-bali.ac.id¹, angga_pradipta@stikom-bali.ac.id^{2*}, roy@stikom-bali.ac.id²

Abstrak


Ulkus kaki, komplikasi serius diabetes, dapat dideteksi dini melalui citra termogram yang mengukur perbedaan suhu pada area kaki. Penelitian ini menilai efektivitas empat model Convolutional Neural Network (CNN) yang telah dilatih sebelumnya—MobileNetV2, VGG16, InceptionV3, dan ResNet101—dalam menganalisis citra termogram untuk deteksi ulkus diabetik. Pengujian melibatkan tiga skenario peningkatan citra: gambar asli, Adaptive Histogram Equalization (AHE), dan Gamma Correction. Evaluasi dilakukan melalui pelatihan, validasi, dan pengujian dengan fokus pada akurasi, presisi, dan efisiensi waktu. Hasil penelitian ini menunjukkan bahwa Gamma Correction meningkatkan performa model MobileNetV2 dengan mencatat peningkatan akurasi hingga 88%, dan model VGG16 mencapai presisi 92%. Studi ini juga menemukan bahwa aplikasi Gamma Correction mengurangi waktu pelatihan dan meningkatkan efisiensi pengolahan citra secara signifikan, menunjukkan potensi besar dalam aplikasi klinis untuk deteksi dini ulkus diabetik. Penggunaan model CNN yang telah dilatih sebelumnya mempercepat proses adaptasi teknologi ini dalam pengaturan klinis, memberikan dasar yang kuat untuk implementasi lebih lanjut dalam praktik medis.

Kata kunci: CNN, deteksi dini diabetes, citra termogram, image enhancement, model pre-trained.

1. Pendahuluan

Diabetes mellitus merupakan salah satu penyakit kronis yang prevalensinya terus meningkat di seluruh dunia. Penyakit ini ditandai dengan tingginya kadar glukosa dalam darah yang dapat menyebabkan berbagai komplikasi serius jika tidak ditangani dengan tepat, termasuk penyakit jantung, gagal ginjal, dan kerusakan saraf. Deteksi dini diabetes penting dilakukan untuk mencegah atau meminimalisir terjadinya komplikasi dan memungkinkan pengelolaan yang lebih efektif dari kondisi tersebut.

Dalam beberapa tahun terakhir, termografi medis telah muncul sebagai metode non-invasif yang menjanjikan untuk deteksi dini berbagai kondisi medis, termasuk diabetes. Termografi menggunakan kamera inframerah untuk mengukur distribusi suhu tubuh yang dapat mengindikasikan adanya perubahan fisiologis yang terkait dengan diabetes.



Gambar 1. Contoh citra termogram telapak kaki yang terdapat pada dataset

Pada penelitian sebelumnya telah mengeksplorasi penggunaan model CNN yang telah dilatih sebelumnya untuk klasifikasi gambar yang terkait dengan diabetes. Khandakar (2021)[5] dan Khandakar (2022)[6] keduanya mencapai akurasi tinggi dalam mengklasifikasikan gambar termogram kaki diabetik menggunakan teknik *machine learning*, dengan yang pertama mencapai skor F1 sebesar 95% dan yang kedua mencapai akurasi sebesar 90,1%. Demikian pula, Ghosh (2017)[7] dan Mobeen-ur-Rehman (2019)[8] keduanya menggunakan CNN untuk mendeteksi dan mengklasifikasikan retinopati diabetik, dengan Ghosh mencapai akurasi 95% untuk klasifikasi dua kelas dan 85% untuk klasifikasi lima kelas, dan Mobeen-ur-Rehman mencapai akurasi klasifikasi sebesar 93,46%, 91,82%, dan 94,49% menggunakan model CNN yang telah dilatih sebelumnya. Kolektif studi ini menunjukkan potensi model CNN yang telah dilatih sebelumnya dalam mengklasifikasikan gambar yang terkait dengan diabetes secara akurat.

Mengingat keberhasilan penggunaan CNN dalam berbagai setting medis, penelitian ini bertujuan untuk menganalisis dan membandingkan performa dari empat arsitektur CNN yang berbeda *MobileNetV2*, *VGG16*, *InceptionV3*, dan *ResNet101* dalam mengklasifikasikan citra termogram untuk deteksi dini diabetes. Penelitian ini diharapkan dapat mengevaluasi akurasi dan kecepatan pengolahan dari masing-masing model, serta memberikan wawasan baru mengenai aplikabilitas teknologi ini dalam konteks medis. Melalui analisis komprehensif, studi ini berupaya memberikan kontribusi pada pengembangan metode diagnostik yang lebih akurat, serta membuka peluang untuk aplikasi praktis teknologi ini dalam lingkungan medis.

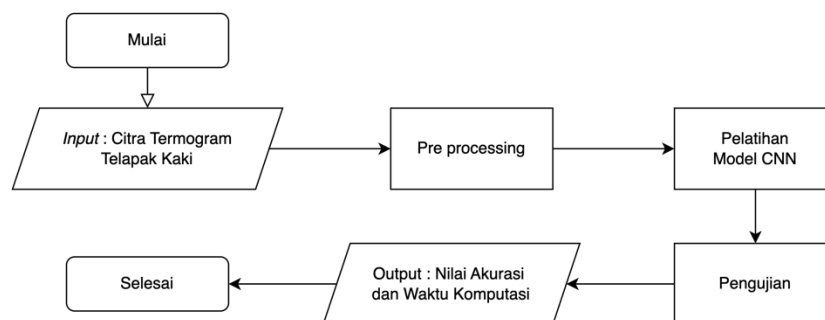
2. Metode Penelitian

2.1 Dataset

Data citra termogram yang digunakan diambil dari IEEE Dataport [9], data yang berisi gambar termal (*thermograms*) dari daerah plantar kaki. Dataset ini diperoleh dari 122 subjek dengan diagnosis diabetes (kelompok DM) dan 45 subjek non-diabetes (kelompok CG), maka total data menjadi 334 gambar terdiri dari telapak kaki kiri dan kanan. Dataset yang tersedia berformat PNG dan gambar rata-rata berukuran 63x136 *pixel*. Gambar dengan kelas non-diabetes (CG) dapat dilihat pada Gambar 1 bagian a, b, c dan d, sedangkan bagian e, f, g dan h merupakan pasien yang menderita diabetes (DM).

2.2 Desain Sistem

Gambar 2 menunjukkan diagram alir yang mendetail mengenai prosedur eksperimental untuk evaluasi efektivitas metode CNN dalam deteksi dini diabetes secara dini. Langkah awal melibatkan proses *preprocessing* di mana ukuran setiap gambar dalam dataset diubah menjadi 224x224 piksel dan proses *image enhancement*. Selanjutnya, dataset dibagi menjadi tiga segmen: data pelatihan, data validasi, dan data pengujian. Proses selanjutnya adalah pelatihan menggunakan metode CNN dengan aplikasi teknik *transfer learning*, melibatkan empat jenis model CNN, yaitu *MobileNetV2*, *VGG16*, *InceptionV3*, dan *ResNet101*. Tahap pengujian final akan mengevaluasi dan menampilkan akurasi dari setiap model CNN, berdasarkan data pengujian yang telah disiapkan sebelumnya. *Output* tambahan mencakup perhitungan waktu komputasi yang diperlukan selama proses pelatihan.

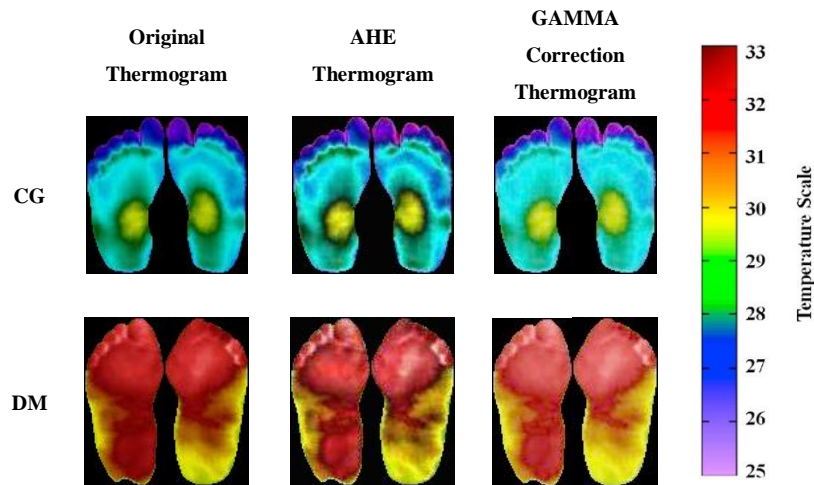


Gambar 2. Diagram alir untuk deteksi dini diabetes.

2.3 Preprocessing

Dalam langkah ini, semua gambar yang akan digunakan untuk pelatihan serta pengujian dimodifikasi ukurannya menjadi 224x224 piksel karena dimensi gambar yang dapat diproses harus persegi. Selanjutnya, gambar tersebut ditingkatkan kualitasnya melalui penerapan *Adaptive Histogram Equalization*


(AHE) dan *Gamma Correction*[5]. Setelah itu, dataset dibagi menjadi tiga bagian: data latih, data validasi, dan data uji. Data latih dan data validasi kemudian digunakan selama tahap pengujian untuk mengevaluasi kinerja dari setiap model CNN.



Gambar 3. Perbandingan antara citra termogram original, AHE dan GAMMA Correction untuk pasien diabetes(DM) dan kontrol(CG).

2.4 Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan metode efektif untuk klasifikasi dalam berbagai jenis data seperti gambar, suara, dan teks. Struktur CNN biasanya terdiri dari tiga lapisan utama: *convolution layer*, *pooling layer*, dan *fully connected layer*. Lapisan *convolution* dan *pooling* berfungsi untuk ekstraksi informasi dari gambar, sedangkan *fully connected layer* bertugas untuk membuat prediksi dan memberikan label yang tepat berdasarkan hasil analisis. Untuk meningkatkan akurasi dan mengurangi kesalahan, berbagai model arsitektur CNN telah dikembangkan, masing-masing dengan konfigurasi layer yang unik dan berbeda.



Gambar 4. Arsitektur Model CNN yang digunakan.

Pre-Trained Model yang digunakan dalam penelitian ini adalah *MobileNetV2*, *VGG16*, *InceptionV3*, dan *ResNet101*. Model *MobileNetV2* merupakan sebuah model CNN yang ringan dan dirancang khusus untuk perangkat *mobile* dan *embedded*, telah berdampak besar terhadap berbagai aplikasi. Berbagai penelitian telah menguji pemanfaatan model CNN *MobileNetV2* yang telah dilatih terlebih dahulu dalam sejumlah penggunaan yang beragam. Mohammed (2022)[10] berhasil mencapai tingkat akurasi klasifikasi sebesar 91% dalam mendeteksi botnet pada Android, sementara model tersebut mencatat waktu pelatihan dan pengujian paling cepat. Dalam studi Yoon (2020)[11], pengenalan ekspresi wajah mencapai akurasi 90,3% untuk lima kelas dan 86,8% untuk tujuh kelas. Contardo (2023)[12] mengintegrasikan *MobileNetV2* dengan lapisan berulang untuk mendeteksi tindak kekerasan dalam video, dan berhasil mencapai akurasi 94,1%. Soongswang (2023)[13] menawarkan modifikasi pada arsitektur *MobileNetV2* untuk pengenalan wajah 3D, yang meningkatkan akurasi sebesar 6,99% dengan penambahan ukuran hanya 0,015%.

Pre-Trained Model VGG16[14], dikenal dengan arsitektur yang lebih tradisional, terdiri dari lapisan *convolutional* berturut-turut yang diikuti oleh lapisan *pooling* dan *fully connected*, cocok untuk pemodelan gambar secara umum. *InceptionV3*[15], dengan struktur blok *convolutional* dan *fully connected* yang serupa dengan *VGG16*, membedakan dirinya dengan integrasi blok *inception* yang memungkinkan penangkapan informasi pada skala berbeda, sangat bermanfaat untuk pemodelan gambar yang kompleks.

ResNet101 menggunakan blok residual yang memanfaatkan hubungan *shortcut* untuk mengirim *output* dari lapisan sebelumnya, memungkinkan pelatihan model yang lebih dalam tanpa menghadapi masalah menghilangnya gradien, sehingga sangat sesuai untuk proses yang memerlukan pemahaman gambar yang mendalam.

Arsitektur model CNN yang diusulkan dalam penelitian ini digambarkan pada Gambar 4 dan menggunakan *pre-trained* model *MobileNetV2*, *VGG16*, *InceptionV3*, dan *ResNet101*, seperti yang telah dijelaskan sebelumnya, tetapi tanpa melibatkan *fully connected layer*. *Pre-trained* model ini disediakan melalui *Keras*, sebuah *high-level* API yang sering digunakan untuk mengatasi masalah yang berkaitan dengan *deep learning*. *Keras* beroperasi di atas *TensorFlow*, memudahkan integrasi dan penerapan dalam berbagai pengembangan model *deep learning*.

Pre-trained model yang digunakan pada penelitian ini sudah dilatih sebelumnya menggunakan dataset *ImageNet*. *ImageNet* merupakan dataset gambar berukuran besar yang sering digunakan oleh peneliti untuk menguji model CNN yang sedang dibangun. Selain *pre-trained* model, ada beberapa layer juga ditambahkan seperti yang terlihat pada Gambar 5 yaitu *Global Average Pooling 2D (GAP) layer*, *dense layer*, *dropout layer*, *batch normalization* dan *output dense layer* atau *fully connected layer*. *GAP layer* dan *dropout layer* digunakan untuk meminimalisir terjadinya *overfitting*.

Fungsi aktivasi yang terdapat di *fully connected layer* adalah fungsi *softmax*. Fungsi ini akan menghitung probabilitas yang umum digunakan pada saat melakukan klasifikasi multi kelas. Fungsi ini biasanya digunakan di bagian akhir dari *fully connected layer* untuk menghasilkan nilai probabilitas suatu objek terhadap kelas yang ada (Goodfellow, Bengio, & Courville, 2016)[14]. Fungsi *softmax* memiliki rentang nilai probabilitas antara 0 dan 1 serta apabila semua nilai probabilitasnya dijumlahkan, hasilnya akan sama dengan satu.

2.5 Pelatihan Model

Tahap pelatihan adalah proses di mana model CNN dilatih menggunakan data yang telah melewati tahap *pre-processing* sebelumnya. Sebelum memulai pelatihan, penting untuk mengatur jumlah *epoch* dan *learning rate*. *Learning rate* adalah *hyperparameter* kritis yang berdampak besar terhadap kinerja model CNN. Dalam penelitian ini, *learning rate* yang ditetapkan adalah 0,001 dan jumlah *epoch* adalah 10. Selama tahap ini, perhitungan waktu komputasi juga dilakukan, yang mana waktu komputasi dihitung berdasarkan durasi yang dibutuhkan untuk melatih setiap model CNN.

3. Hasil dan Pembahasan

Dalam dataset ini terdapat total 334 gambar, yang kemudian dibagi menjadi tiga segmen: 267 gambar untuk pelatihan, 33 gambar untuk validasi, dan 34 gambar untuk pengujian. Setiap segmen diatur sedemikian rupa sehingga tidak ada gambar yang *overlap* antara satu segmen dengan segmen lainnya.

Semua gambar pada ketiga bagian tersebut akan melalui proses *preprocessing* dimana gambar akan diubah ukurannya menjadi 224x224 piksel karena data gambar pada dataset tidak persegi dan kemudian dilakukan proses *image enhancement*. Ada tiga skenario pengujian yang digunakan, seperti yang ditampikan pada Gambar 3, dimana untuk melihat apakah gambar yang melalui proses *image enhancement* mempengaruhi performa dari masing-masing model CNN.

Untuk menemukan model CNN yang memiliki performa paling optimal, penelitian ini melakukan perbandingan antara empat model CNN, yaitu *MobileNetV2*, *VGG16*, *InceptionV3*, dan *ResNet101*. Semua model tersebut dilatih dengan nilai *learning rate* dan jumlah *epoch* yang sama di setiap eksperimen. Selama proses pelatihan, waktu komputasi dari masing-masing model juga dicatat untuk menilai berapa lama waktu yang dibutuhkan oleh tiap model untuk menyelesaikan pelatihan tersebut.

Tabel 1. Waktu komputasi pelatihan masing-masing model dan metode *image enhancement*

Model CNN	Original	AHE	Gamma Correction
MobileNetV2	23.81 detik	3.93 detik	3.72 detik
InceptionV3	191.26 detik	6.18 detik	6.30 detik
VGG16	27.61 detik	10.44 detik	10.32 detik
ResNet101	30.49 detik	13.70 detik	20.57 detik

Hasil percobaan yang terdapat pada Table 1 menunjukkan bahwa *MobileNetV2* menunjukkan waktu komputasi yang signifikan lebih pendek saat menggunakan metode *AHE* dan *Gamma Correction*,
Analisis Performa Pre-Trained Model CNN pada Citra Termogram dalam Deteksi Dini Pasien Diabetes (W. Mega Adhi Agam Pradhana)

dengan waktu masing-masing hanya 3.93 detik dan 3.72 detik, dibandingkan dengan waktu komputasi 23.81 detik untuk citra asli. Sedangkan *InceptionV3*, yang memiliki waktu komputasi terlama dengan citra asli sebesar 191.26 detik, menunjukkan penurunan waktu yang drastis hingga hanya 6.18 detik dan 6.30 detik dengan AHE dan *Gamma Correction*. *VGG16* dan *ResNet101* juga menunjukkan penurunan waktu komputasi yang signifikan saat menggunakan kedua metode tersebut dibandingkan dengan citra asli. Hasil ini menunjukkan bahwa penggunaan AHE dan *Gamma Correction* dapat secara efektif mengurangi waktu komputasi dalam pengolahan citra termogram untuk deteksi dini pasien diabetes.

Tabel 2. Matrik evaluasi masing-masing model dan metode *image enhancement*

Model CNN	Image Enhancement	Accuracy	Precision	Recall	F1 Score
MobileNetV2	Original	88.24%	87.30%	81.33%	83.65%
	AHE	82.35%	81.54%	82.35%	81.59%
	Gamma	88.24%	88.24%	88.24%	88.24%
InceptionV3	Original	88.24%	93.10%	77.78%	82.01%
	AHE	82.35%	81.54%	82.35%	81.59%
	Gamma	73.53%	54.07%	73.53%	62.31%
VGG16	Original	82.35%	81.54%	82.35%	81.59%
	AHE	91.18%	92.12%	91.18%	90.54%
	Gamma	85.29%	85.08%	85.29%	84.24%
ResNet101	Original	88.24%	88.05%	88.24%	87.73%
	AHE	82.35%	81.54%	82.35%	81.59%
	Gamma	85.29%	84.90%	85.29%	85.01%

Hasil pengujian menunjukkan beberapa temuan mengenai performa model tersebut yang ditunjukkan pada Tabel 2 yaitu *Accuracy*, *Precision*, *Recall*, dan *F1 Score*. Secara umum, model *ResNet101* dan *MobileNetV2* mencatat performa yang tinggi dengan penggunaan *Gamma Correction*, menunjukkan konsistensi dalam semua metrik dengan nilai sekitar 90%. Model *InceptionV3* dan *VGG16* juga menunjukkan peningkatan performa signifikan dengan metode *Gamma Correction*, dengan nilai metrik serupa pada sekitar 88%. Sebaliknya, metode AHE cenderung menghasilkan penurunan dalam performa, dengan nilai *accuracy*, *precision*, *recall*, dan *F1 Score* umumnya berkisar 82%. Hal ini menegaskan bahwa *Gamma Correction* dapat secara efektif mempertahankan atau bahkan meningkatkan kualitas citra.

4. Kesimpulan

Dari eksperimen yang dilakukan pada model-model *pretrained CNN* untuk deteksi dini pasien diabetes menggunakan citra termogram, hasil yang diperoleh menunjukkan bahwa teknik *Gamma Correction* secara signifikan meningkatkan performa model dibandingkan dengan teknik AHE. Model *ResNet101* dan *MobileNetV2*, khususnya, mencatat performa yang cukup tinggi dengan penggunaan *Gamma Correction*, menunjukkan konsistensi dalam semua metrik performa dengan nilai yang mendekati 90%. Sedangkan *InceptionV3* dan *VGG16* juga menunjukkan peningkatan yang signifikan dalam performa dengan nilai metrik yang serupa, berkisar di sekitar 88%. Metode AHE, sebaliknya cenderung menghasilkan penurunan performa dengan nilai metrik rata-rata sekitar 82%. Selain itu, penggunaan *Gamma Correction* dan AHE juga berhasil mengurangi waktu komputasi secara drastis dibandingkan dengan penggunaan citra asli, dengan *MobileNetV2* dan *InceptionV3* menunjukkan penurunan waktu komputasi yang paling signifikan. Kesimpulannya, *Gamma Correction* terbukti lebih efektif daripada AHE dalam meningkatkan kualitas citra termogram untuk analisis oleh model-model CNN, sehingga meningkatkan akurasi deteksi dalam aplikasi klinis.

Daftar Pustaka

- [1] P.Haripriya and R.Porkodi, "Deep Learning Pre-Trained Architecture Of Alex Net And Googlenet For DICOM Image Classification," 2020. [Online]. Available: <https://api.semanticscholar.org/CorpusID:212473595>
- [2] O. Lantang, G. H. Terdik, A. Hajdu, and A. Tiba, "Investigation of the efficiency of an interconnected convolutional neural network by classifying medical images," *Annales Mathematicae et Informaticae*, 2021, [Online]. Available: <https://api.semanticscholar.org/CorpusID:236664917>
- [3] E. S. Nugroho, I. Ardiyanto, and H. A. Nugroho, "Comparative Performance of Pre-Trained CNN Architectures on Dermoscopic Pigmented Skin Lesions Classification," *2023 3rd International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, pp. 327–331, 2023, [Online]. Available: <https://api.semanticscholar.org/CorpusID:266196323>
- [4] D. O. Alebiosu and F. P. Muhammad, "Medical Image Classification: A Comparison of Deep Pre-trained Neural Networks," *2019 IEEE Student Conference on Research and Development (SCoReD)*, pp. 306–310, 2019, [Online]. Available: <https://api.semanticscholar.org/CorpusID:208034597>
- [5] A. Khandakar *et al.*, "A machine learning model for early detection of diabetic foot using thermogram images," *Comput Biol Med*, vol. 137, Oct. 2021, doi: 10.1016/j.compbiomed.2021.104838.
- [6] A. Khandakar *et al.*, "Thermal Change Index-Based Diabetic Foot Thermogram Image Classification Using Machine Learning Techniques," *Sensors*, vol. 22, no. 5, Mar. 2022, doi: 10.3390/s22051793.
- [7] R. Ghosh, K. Ghosh, and S. Maitra, "Automatic detection and classification of diabetic retinopathy stages using CNN," *2017 4th International Conference on Signal Processing and Integrated Networks (SPIN)*, pp. 550–554, 2017, [Online]. Available: <https://api.semanticscholar.org/CorpusID:35668197>
- [8] Mobeen-ur-Rehman, S. H. Khan, Z. Abbas, and S. M. D. Rizvi, "Classification of Diabetic Retinopathy Images Based on Customised CNN Architecture," in *2019 Amity International Conference on Artificial Intelligence (AICAI)*, 2019, pp. 244–248. doi: 10.1109/AICAI.2019.8701231.
- [9] Daniel Hernández-Contreras; Hayde Peregrina-Barreto; Jose Rangel-Magdaleno; Francisco Renero-Carrillo, "Plantar Thermogram Database for the Study of Diabetic Foot Complications," IEEE Dataport.
- [10] A. S. Mohammed, S. Seher, S. Y. Yerima, and A. Bashar, "A Deep Learning based Approach to Android Botnet Detection using Transfer Learning," *2022 14th International Conference on Computational Intelligence and Communication Networks (CICN)*, pp. 543–548, 2022, [Online]. Available: <https://api.semanticscholar.org/CorpusID:255778299>
- [11] C. Yoon and D. Kim, "Mobile Convolutional Neural Networks for Facial Expression Recognition," *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, pp. 1315–1317, 2020, [Online]. Available: <https://api.semanticscholar.org/CorpusID:229376059>
- [12] P. Contardo, S. Tomassini, N. Falcionelli, A. F. Dragoni, and P. Sernani, "Combining a mobile deep neural network and a recurrent layer for violence detection in videos," in *International Conference on Recent Trends and Applications in Computer Science and Information Technology*, 2023. [Online]. Available: <https://api.semanticscholar.org/CorpusID:259115432>
- [13] K. Soongswang, P. Romphet, and C. Chantrapornchai, "Enhancing MobileNetV2 Performance with Layer Replication and Splitting for 3D Face Recognition Task Using Distributed Training," *2023 International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC)*, pp. 1–6, 2023, [Online]. Available: <https://api.semanticscholar.org/CorpusID:260933472>
- [14] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.