

Prihanto Dwi Rahmanto
NIM: 22206051021



**OPTIMASI HYPERPARAMETER
PADA ARSITEKTUR MODEL CNN LIGHTWEIGHT
UNTUK DETEKSI SPOOFING WAJAH MENGGUNAKAN OPTUNA**



2025

**OPTIMASI *HYPERPARAMETER*
PADA ARSITEKTUR MODEL CNN *LIGHTWEIGHT*
UNTUK DETEKSI *SPOOFING* WAJAH
MENGUNAKAN OPTUNA**



Oleh:

Prihanto Dwi Rahmanto

NIM. 22206051021

**PROGRAM STUDI INFORMATIKA
PROGRAM MAGISTER FAKULTAS SAINS DAN
TEKNOLOGI
UIN SUNAN KALIJAGA**

YOGYAKARTA

2025

PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini:

Nama : Prihanto Dwi Rahmanto

NIM : 22206051021

Jenjang : Magister

Program Studi : Informatika

menyatakan bahwa naskah tesis ini secara keseluruhan adalah hasil penelitian/ karya saya sendiri, kecuali pada bagian-bagian yang dirujuk sumbernya.

Yogyakarta, 11 Juli 2025

Saya yang menyatakan,



Prihanto Dwi Rahmanto

NIM: 22206051021

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

PERNYATAAN BEBAS PLAGIASI

Yang bertanda tangan di bawah ini:

Nama : Prihanto Dwi Rahmanto

NIM : 22206051021

Jenjang : Magister

Program Studi : Informatika

menyatakan bahwa naskah tesis ini secara keseluruhan benar-benar bebas dari plagiasi.

Jika di kemudian hari terbukti melakukan plagiasi, maka saya siap ditindak sesuai ketentuan hukum yang berlaku.

Yogyakarta, 11 Juli 2025

Saya yang menyatakan,



Prihanto Dwi Rahmanto

NIM: 22206051021

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
FAKULTAS SAINS DAN TEKNOLOGI

Jl. Marsda Adisucipto Telp. (0274) 540971 Fax. (0274) 519739 Yogyakarta 55281

PENGESAHAN TUGAS AKHIR

Nomor : B-1790/Un.02/DST/PP.00.9/08/2025

Tugas Akhir dengan judul : Optimasi Hyperparameter pada Arsitektur Model CNN Lightweight untuk Deteksi Spoofing Wajah Menggunakan Optuna

yang dipersiapkan dan disusun oleh:

Nama : PRIHANTO DWI RAHMANTO, S. Kom.
Nomor Induk Mahasiswa : 22206051021
Telah diujikan pada : Senin, 21 Juli 2025
Nilai ujian Tugas Akhir : A-

dinyatakan telah diterima oleh Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta

TIM UJIAN TUGAS AKHIR



Valid ID: 689d33560bab9

Ketua Sidang

Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng.
SIGNED



Valid ID: 68886ced6acca

Penguji I

Ir. Maria Ulfah Siregar, S.Kom., MIT., Ph.D.
SIGNED



Valid ID: 689a09d3461aa

Penguji II

Dr. Agus Mulyanto, S.Si., M.Kom., ASEAN Eng.
SIGNED



Valid ID: 689f375f1620e

Yogyakarta, 21 Juli 2025
UIN Sunan Kalijaga
Dekan Fakultas Sains dan Teknologi

Prof. Dr. Dra. Hj. Khurul Wardati, M.Si.
SIGNED



BERITA ACARA UJIAN TUGAS AKHIR

Penyelenggaraan Ujian Tugas Akhir Mahasiswa

A. Waktu, Tempat dan Status Ujian Tugas Akhir:

1. Hari dan Tanggal : Senin, 21 Juli 2025
2. Pukul : 08:00 s/d 09:00 WIB
3. Tempat : FST-1-102
4. Status : Utama

B. Susunan Tim Ujian Tugas Akhir:

No.	Jabatan	Nama	Tanda Tangan
1.	Ketua Sidang	Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng.	 Valid ID: 689d333041d0f
2.	Penguji I	Ir. Maria Ulfah Siregar, S.Kom., MIT., Ph.D.	 Valid ID: 68886cc9759c4
3.	Penguji II	Dr. Agus Mulyanto, S.Si., M.Kom., ASEAN Eng.	 Valid ID: 689a09aa23f14

C. Identitas Mahasiswa yang diuji:

1. Nama : PRIHANTO DWI RAHMANTO, S. Kom.
2. Nomor Induk Mahasiswa : 22206051021
3. Program Studi : S2 - Informatika
4. Semester : V
5. Program : S2
6. Status Kehadiran Mahasiswa : Menghadiri Ujian

D. Judul Tugas Akhir : Optimasi Hyperparameter pada Arsitektur Model CNN Lightweight untuk Deteksi Spoofing Wajah Menggunakan Optuna

E. Pembimbing/Promotor:

1. Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng.

F. Keputusan Sidang

1. LULUS dengan Perbaikan
2. Predikat Kelulusan : 94.00 (A-)
3. Konsultasi Perbaikan a. _____
b. _____



Valid ID: 689d333041d0f

Yogyakarta, 21 Juli 2025
Ketua Sidang/Pembimbing/Promotor,

Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom.,
IPM., ASEAN Eng.
SIGNED

NOTA DINAS PEMBIMBING

Kepada Yth.,
Dekan Fakultas Sains dan Teknologi
UIN Sunan Kalijaga Yogyakarta

Assalamu 'alaikum wr. wb.

Setelah melakukan bimbingan, arahan, dan koreksi terhadap penulisan tesis yang berjudul:

**OPTIMASI HYPERPARAMETER
PADA ARSITEKTUR MODEL CNN LIGHTWEIGHT
UNTUK DETEKSI SPOOFING WAJAH MENGGUNAKAN OPTUNA**

Yang ditulis oleh:

Nama : Prihanto Dwi Rahmanto

NIM : 22206051021

Jenjang : Magister

Program Studi : Informatika

Saya berpendapat bahwa tesis tersebut sudah dapat diajukan kepada Magister Informatika UIN Sunan Kalijaga untuk diujikan dalam rangka memperoleh gelar Magister Informatika.

Wassalamu'alaikum wr. wb.

Yogyakarta, 14 Juli 2025

Pembimbing,



(Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom.)

ABSTRAK

Untuk mendapatkan pengaturan hyperparameter tuning secara tradisional dikenal adanya metode grid dan random search. Namun kedua metode ini memiliki keterbatasan dalam menentukan kumpulan hyperparameter ketika proses pelatihan model. Disamping itu metode tersebut juga memiliki keterbatasan cakupan parameter serta efisiensi waktu. Sehingga peneliti mencoba untuk menggunakan pengoptimal hyperparameter dengan metode bayesian untuk dapat mengatasi keterbatasan tersebut. Dimana pengoptimal dengan metode bayesian dapat melacak hasil sebelumnya untuk memilih hyperparameter terbaik guna dievaluasi.

Dalam penelitian ini dengan pendekatan optimalisasi bayesian digunakan untuk mendeteksi spoofing wajah pada model CNN lightweight. Model yang dipakai adalah LMFRNet, MobileNetV3 Small, ShuffleNetV2 dan ResNet50 dengan dataset CelebA-Spoof. Framework Optuna dipilih dalam optimalisasi hyperparameter dengan pendekatan bayesian karena kemudahan define-by-run. Proses optimalisasi hyperparameter diawali dengan pra-pemrosesan yang meliputi proses mendeteksi dan fitting wajah menggunakan algoritma MTCNN. Kemudian data cleaning dilakukan untuk mendapatkan data latih yang berkualitas. Algoritma CLAHE ditambahkan untuk meningkatkan kecerahan gambar agar kinerja model lebih baik. Selanjutnya digunakan metode undersampling dalam penyeimbangan data. Selanjutnya dilakukan pemodelan dengan menggunakan metode transfer learning.

Dari penelitian diperoleh pengaturan hyperparameter yang tepat model ShuffleNetV2, ResNet50 dan MobileNetV3 Small untuk learning rate ada pada 0,001, batch size 64 epochs 6 dan optimizer SGD. Adapun untuk model LMFRNet learning rate pada 0,01, batch size 32 epochs 8 dan optimizer SGD. Kinerja terbaik dicapai model ShuffleNetV2 dengan akurasi sebesar 0.98.

Kata Kunci: Hyperparameter Tuning, Optimalisasi Bayesian, CNN Lightweight, Spoofing Wajah

ABSTRACT

Traditionally, hyperparameter tuning relies on grid search or random search, but these methods suffer from inefficiencies in exploring large hyperparameter spaces and often demand extensive computational time. To address these limitations, researchers increasingly use Bayesian optimization, which builds a surrogate model from past trials to guide the selection of promising hyperparameters.

In this study, we applied Bayesian optimization using the Optuna framework - chosen for its flexible "define-by-run" interface - to improve face spoofing detection with lightweight CNNs: LMFRNet, MobileNetV3 Small, ShuffleNetV2, and ResNet50, on the CelebA-Spoof dataset. The preprocessing pipeline included MTCNN-based face detection and alignment, followed by data cleaning, CLAHE for brightness enhancement, and undersampling for class balance. Transfer learning was then applied to train the CNN models.

Bayesian optimization yielded these optimal hyperparameters: for ShuffleNetV2, ResNet50, and MobileNetV3 Small, a learning rate of 0.001, batch size of 64, six epochs, and SGD optimizer; for LMFRNet, a learning rate of 0.01, batch size of 32, eight epochs, and SGD. Among these, ShuffleNetV2 achieved the best performance, reaching 98% accuracy.

Keywords: Hyperparameter Tuning, Bayesian Optimization, CNN Lightweight, Face Spoofing

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

KATA PENGANTAR

Segala Puji dan Syukur Kehadirat Allah SWT atas segala limpahan rahmat dan karunia-Nya, akhirnya penulis dapat menyelesaikan penyusunan tesis yang berjudul: **OPTIMASI HYPERPARAMETER PADA ARSITEKTUR MODEL CNN LIGHTWEIGHT UNTUK DETEKSI SPOOFING WAJAH MENGGUNAKAN OPTUNA.**

Tesis ditulis dalam rangka memenuhi sebagai persyaratan untuk memperoleh gelar Magister di UIN Sunan Kalijaga Yogyakarta. Penulis menyadari bahwa tesis dapat diselesaikan berkat dukungan dan bantuan dari berbagai pihak, oleh karena itu penulis berterima kasih kepada semua pihak yang secara langsung maupun tidak langsung memberikan kontribusi dalam menyelesaikan Tesis ini. Selanjutnya ucapan terima kasih penulis sampaikan kepada:

1. Bapak Prof. Noorhaidi Hasan, S.Ag., M.A., M.Phil., Ph.D. sebagai Rektor UIN Sunan Kalijaga Yogyakarta
2. Bapak Dr. Ir. Sumarsono, S.T., M.Kom. sebagai Kepala Program Studi Magister Informatika Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta, yang telah memberikan izin dan kemudahan sehingga penulis dapat menyelesaikan studi di Program Studi Program Magister Informatika Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta.
3. Ibu Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng. sebagai pembimbing, dengan kesibukannya masih tetap meluangkan waktunya untuk memberikan bimbingan, petunjuk, dan

mendorong semangat penulis untuk menyelesaikan penulisan tesis ini.

4. Seluruh dosen dan staf administrasi pada Program Studi Informatika Program Magister Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta, yang secara langsung atau tidak langsung telah memberi bantuan kepada penulis dalam menyelesaikan penulisan tesis.
5. Segenap Pimpinan dan staf UPT. Pusat Teknologi Informasi dan Pangkalan Data UIN Sunan Kalijaga Yogyakarta yang secara langsung atau tidak langsung telah memberi bantuan dan dukungan kepada penulis dalam menyelesaikan penulisan tesis.
6. Orang tua tercinta yang mendidik dengan penuh rasa kasih sayang dan senantiasa mendo'akan kebaikan kepada penulis.
7. Keluarga tercinta yang senantiasa mendo'akan, memberikan semangat dan dukungan kepada penulis.
8. Seluruh rekan-rekan sejawat di Magister Informatika yang telah saling mendukung untuk melalui perjuangan bersama-sama.
9. Akhirnya penulis berharap semoga Tesis ini dapat bermanfaat dan permintaan maaf yang tulus jika seandainya dalam penulisan ini terdapat kekurangan dan kekeliruan, penulis juga menerima kritik dan saran yang bersifat membangun demi menyempurnakan penulisan tesis ini.

Yogyakarta, 11 Juli 2025

Penulis

Prihanto Dwi Rahmanto

NIM. 22206051021

DAFTAR ISI

PERNYATAAN KEASLIAN.....	ii
PERNYATAAN BEBAS PLAGIASI.....	iii
PERSETUJUAN TIM PENGUJI UJIAN.....	v
NOTA DINAS PEMBIMBING.....	vi
ABSTRAK.....	vii
ABSTRACT.....	viii
KATA PENGANTAR.....	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xiv
BAB I.....	1
A. Latar Belakang.....	1
B. Rumusan Masalah.....	4
C. Batasan Masalah.....	5
D. Tujuan Penelitian.....	5
E. Manfaat Penelitian.....	6
BAB II.....	7
A. Kajian Pustaka.....	7
B. Landasan Teori.....	12
1. Sistem Keamanan <i>Biometrik</i>	12
2. Pemalsuan (<i>Spoofing</i>) Wajah.....	14
3. Deteksi <i>Spoofing</i> Wajah.....	16
4. <i>Deep Learning (DL)</i> Dalam Deteksi <i>Spoofing</i> Wajah.....	17
5. LMFRNet.....	20

6. MobileNetV3 Small.....	21
7. ShuffleNetV2.....	22
8. ResNet50.....	24
9. MTCNN.....	25
10. CLAHE.....	27
11. <i>Transfer Learning</i>	28
12. <i>Fine Tuning</i>	30
13. Bayesian Optimization.....	30
14. Optuna.....	31
15. K-Fold Cross-Validation.....	33
BAB III.....	34
A. Jenis dan Desain Penelitian.....	34
B. Perangkat.....	36
C. Pengumpulan Data (<i>Data Collection</i>).....	36
D. Pra Pemrosesan Data (<i>Data Pre Processing</i>).....	37
E. Pengaturan Model CNN (<i>CNN Model Setup</i>).....	38
F. Pengoptimalan <i>Hyperparameter</i> (<i>Hyperparameter Optimization</i>)	38
BAB IV.....	42
A. Pengumpulan Data (<i>Data Collection</i>).....	42
B. Pra Pemrosesan Data (<i>Data Pre Processing</i>).....	43
1. Deteksi dan <i>Fitting</i> Wajah.....	43
2. Pembersihan Data (<i>Data Cleaning</i>).....	46
3. Penyeimbangan Data (<i>Data Balancing</i>).....	50
C. Pengaturan Model CNN (<i>CNN Model Setup</i>).....	53

D. Pengoptimalan Hyperparameter (Hyperparameter Optimization)	54
BAB V	77
A. Kesimpulan	77
B. Saran	77
DAFTAR PUSTAKA	78



DAFTAR TABEL

Tabel 1: <i>Penelitian</i> Sebelumnya.....	10
Tabel 2: Confusion Matrix.....	40
Tabel 3: Jumlah parameter model transfer learning.....	54
Tabel 4: Hasil evaluasi awal model CNN menggunakan K-Fold Cross Validation.....	55
Tabel 5: Distribusi data model ShuffleNetV2.....	56
Tabel 6: Distribusi data model MobileNetV3 Small.....	59
Tabel 7: Distribusi data model LMFRNet.....	61
Tabel 8: Distribusi data model ResNet50.....	63
Tabel 9: Nilai evaluasi akurasi model CNN.....	67
Tabel 10: Nilai evaluasi presisi model per trial.....	68
Tabel 11: Nilai evaluasi recall model CNN.....	68
Tabel 12: Nilai evaluasi F1-Score model per trial.....	69
Tabel 13: Nilai evaluasi AUC-ROC model per trial.....	69
Tabel 14: Hasil Hyperparameter Model Lightweight.....	73
Tabel 15: Hasil evaluasi Model CNN menggunakan optimasi Bayesian	74
Tabel 16: Perbandingan pencapaian akurasi terbaik dengan penelitian sebelumnya.....	75
Tabel 17: Penggunaan Sumber Daya Model Lightweight.....	76

DAFTAR GAMBAR

Gambar 1: Deep Learning (Gupta et al., 2022).....	18
Gambar 2. Arsitektur CNN (Gupta et al., 2022).....	19
Gambar 3. (a) Gambaran umum model. (b) Struktur Stage 1 dan Stage 6. (c) Keseluruhan struktur Stages 2 sampai 5. (d) Struktur blok MF (Wan & Yao, 2023).....	21
Gambar 4: Arsitektur MobileNetV3 (A. Howard et al., 2019).....	22
Gambar 5: Arsitektur ShuffleNetV2 (<i>Ma et al., 2018</i>).....	23
Gambar 6: Arsitektur ResNet50 (Dharma et al., 2023).....	24
Gambar 7: Perbandingan Traditional Machine Learning dan Transfer Learning (Hosna et al., 2022).....	29
Gambar 8: Contoh program define-by-run API Optuna (Akiba et al., 2019).....	32
Gambar 9: K-Fold Cross Validation (Shen, 2020).....	33
Gambar 10: Tahapan Penelitian.....	35
Gambar 11: Struktur dataset CelebA-Spoof.....	42
Gambar 12: Distribusi dataset berdasarkan jenis spoof.....	43
Gambar 13: Hasil deteksi dan fitting wajah.....	44
Gambar 14: Data gambar yang memiliki tingkat kecerahan kurang dari 30%.....	45
Gambar 15: Hasil peningkatan kecerahan menggunakan algoritma CLAHE.....	46
Gambar 16: Missing data.....	47
Gambar 17: Gambar yang sesuai.....	48

Gambar 18: Kategori missing data lainnya, (a) wajah tidak menghadap kedepan, (b) wajah lebih dari satu, (c) wajah kecil tidak proporsional dengan gambar, (d) ada tulisan atau watermark, (e) blur, (f) riasan berlebih, (g) berkacamata, (h) Bermasker, (i) tertutup tangan, (j) wajah tertutup kain, (k) memakai topi, (l) wajah tertutup kacamata dan kain.	49
Gambar 19: Hasil Penyeimbangan Data.....	51
Gambar 20: Proses data sampling dan data balancing.....	52
Gambar 21: Transfer learning model CNN.....	53
.....	66
Gambar 22: Nilai loss training model CNN.....	66
.....	66
Gambar 23: Nilai akurasi training model CNN.....	66
Gambar 24: Grafik hasil evaluasi model.....	70
Gambar 25: Hasil hyperparameter model ShuffleNetV2.....	71
Gambar 26: Hasil hyperparameter model MobileNetV3 Small.....	71
Gambar 27: Hasil hyperparameter model ResNet50.....	72
Gambar 28: Hasil hyperparameter model LMFRNet.....	72

BAB I

PENDAHULUAN

A. Latar Belakang

Kebutuhan terhadap sistem autentikasi yang tangguh untuk menjamin pengguna aplikasi adalah orang yang berhak, menjadi kebutuhan yang wajib di era perkembangan teknologi seperti saat ini. Beragam sistem autentikasi yang dapat digunakan diantaranya mulai dari penggunaan *password*, OTP (*One Time Password*), MFA (*Multi Factor Authentication*), *Token* atau autentikasi biometrik. Dan autentikasi biometrik menjadi salah satu pilihan yang tepat, karena disamping memberikan kemudahan bagi pengguna karena tidak perlu mengingat dan memasukkan *password* atau semisalnya. Autentikasi ini menggunakan karakter unik pada fisik seseorang, seperti sidik jari, iris mata ataupun wajah sehingga sangat sulit untuk dipalsukan atau dicuri.

Adapun autentikasi biometrik menggunakan wajah biasa disebut dengan sistem pengenalan wajah. Metode ini didasarkan pada karakteristik wajah yang ditangkap oleh sensor kamera kemudian diuji dengan algoritma tertentu. Adapun algoritma yang digunakan pun berbeda-beda tergantung pada beberapa hal seperti sensor, waktu, gerakan tubuh/posisi, ekspresi dan lain sebagainya. Kompleksitas algoritma yang digunakan dapat menyebabkan variasi pada keakuratan

hasil pengenalan wajah (Agusti & Gisela, 2020). Adapun sekarang ini sistem pengenalan wajah telah melibatkan model kecerdasan buatan

melalui pembelajaran mendalam. Model ini akan dilakukan serangkaian proses latihan dan ujicoba untuk dapat mengenali wajah seseorang sampai pada level akurasi tertinggi. Kemudian model ini agar dapat diterapkan di gadget, haruslah berukuran kecil sehingga aplikasi tetap ringan dan tidak memakan memori yang banyak namun memiliki tingkat akurasi tinggi. Diantara model yang memiliki fungsi general dalam komputer vision dan sering digunakan untuk pengenalan wajah diantaranya MobileNet, ShuffleNet dan EfficientNet (Chi et al., 2023).

Namun dalam penerapannya semisal di layanan *boarding gate* kereta api, ujian mandiri, presensi pegawai atau siswa, *face ID* dan lain sebagainya, sistem pengenalan wajah memiliki kerentanan terhadap berbagai serangan presentasi/ Presentation Attack (PA), seperti serangan menggunakan gambar/ foto cetak, pemutaran ulang (replay), tata rias, topeng 3D, dll. Serangan ini akan dapat mengelabui (spoofing) sistem dan menganggap apa yang ditangkap oleh sistem adalah benar padahal yang asli sebaliknya. Oleh karena itu, banyak pihak memberikan perhatian besar untuk mengembangkan teknologi face anti-spoofing (FAS) untuk mengamankan sistem pengenalan wajah (Yu et al., 2023). Dalam konteks pembelajaran mendalam, diantara upaya yang dilakukan untuk mencegah pemalsuan wajah diantara dengan membuat suatu dataset khusus untuk mendeteksi

pemalsuan (spoof) wajah, model khusus untuk deteksi spoofing wajah atau model yang memiliki fungsi general dalam pengklasifikasian pada penerapannya di komputer vision namun bisa juga digunakan untuk pemodelan deteksi pemalsuan wajah.

Pendekatan berbasis *Convolutional Neural Network* (CNN) telah menunjukkan kinerja yang baik dalam deteksi spoofing (Y. Liu et al., 2018). Tetapi tantangan utama terletak pada optimalisasi model lightweight agar efisien secara komputasi tanpa mengorbankan akurasi. Penelitian baru terhadap model ringan berbasis CNN khusus untuk pengklasifikasian gambar dengan nama LMFRNet. Model ini memiliki akurasi hingga 94,60% dengan total parameter 0,52M ketika diujicobakan untuk klasifikasi citra pada dataset CIFAR10 (Wan & Yao, 2023). Kinerja LMFRNet sangat bergantung pada pemilihan *hyperparameter* seperti *learning rate*, ukuran *batch* serta *optimizer* yang digunakan. Seringkali pemilihan *hyperparameter* dilakukan secara manual sehingga menjadikan kurang efisien.

Diantara teknik pengoptimalan tradisional yaitu dengan metode *grid* dan *random search*. Yang mana keduanya memiliki keunggulan dibanding dengan teknik manual. Hanya saja kedua metode ini tidak dapat menentukan kumpulan *hyperparameter* berikutnya ketika proses pelatihan terhadap model. Selain itu, metode *grid search* melatih semua kemungkinan kombinasi *hyperparameter*. Proses ini akan memakan waktu yang lama. Walau kendala ini dapat diatasi dengan metode *random search*, dengan memilih parameter secara acak

sehingga dapat memangkas waktu pelatihan. Namun metode *random search* memiliki keterbatasan dalam cakupan parameter. Kendala ini kemudian dapat diatasi dengan pengoptimalan model berbasis *bayesian*. Pengoptimalan *bayesian* melacak hasil sebelumnya untuk memilih *hyperparameter* terbaik guna dievaluasi. Pengoptimalan *bayesian* telah digunakan dalam berbagai model dan simulasi pada *machine learning*, terutama pada algoritma-algoritma berbasis *computer vision*. Biasanya digunakan untuk menyetel *hyperparameter* demi mendapatkan kinerja model yang lebih baik. Metode ini sangat membantu dalam merumuskan tugas berat ketika mengoptimalkan banyak parameter (Victoria & Maragatham, 2021).

Optuna merupakan salah satu *framework hyperparameter optimization*, yang menawarkan solusi dengan pendekatan *Bayesian optimization* untuk mengeksplorasi ruang pencarian *hyperparameter* secara sistematis (Akiba et al., 2019). Oleh karena itu peneliti bermaksud melakukan penelitian dalam mengoptimalkan *hyperparameter* pada arsitektur model CNN salah satunya LMFRNet menggunakan Optuna untuk meningkatkan kinerja deteksi spoofing serta mengidentifikasi *hyperparameter* yang paling tepat.

B.Rumusan Masalah

Berdasarkan penjelasan latar belakang yang sudah dibahas, rumusan masalah yang dapat ditetapkan adalah bagaimana melakukan

optimalisasi *hyperparameter* pada model CNN *lightweight* menggunakan metode bayesian dengan *framework* Optuna?

C. Batasan Masalah

Untuk mencegah pembahasan yang terlalu luas, penelitian ini fokus pada optimasi *hyperparameter* dengan menggunakan optuna dalam mendeteksi serangan *spoofing* wajah berbasis model-model CNN *lightweight*, yaitu LMFRNet, MobileNetV3 Small, ShuffleNetV2, dan ResNet50. Pengujian dilakukan menggunakan dataset CelebA-Spoof, terutama untuk jenis serangan seperti print, papercut, dan replay. *Framework* pengoptimal *hyperparameter* menggunakan *Optuna optimization* untuk mendapatkan pengaturan yang sesuai untuk masing-masing model. Untuk mendeteksi wajah digunakan algoritma MTCNN. Kemudian untuk membantu model dalam mengenali data ditambahkan algoritma CLAHE yang berfungsi meningkatkan kecerahan pada gambar. Seluruh proses penelitian dilakukan menggunakan pemrograman dilakukan di lingkungan *Jupyter Notebook*.

D. Tujuan Penelitian

Berdasarkan dari rumusan dan batasan masalah diatas, maka tujuan dari penelitian ini adalah melakukan optimasi *hyperparameter* pada model CNN *lightweight* menggunakan dataset spoofing wajah menggunakan metode bayesian dengan *framework* Optuna, Dari proses

optimalisasi tersebut dihasilkan nilai *hyperparameter* yang tepat untuk masing-masing model yang dapat digunakan untuk mendeteksi *spoofing* wajah.

E. Manfaat Penelitian

Dari hasil penelitian yang telah dilakukan, diharapkan dapat memberikan manfaat sebagai berikut:

1. Pengaturan *hyperparameter* yang optimal pada model *lightweight* untuk meningkatkan kinerja model menggunakan metode bayesian dengan framework Optuna.
2. Peningkatan kinerja model CNN *lightweight* dalam akurasi, presisi, *recall* dan skor F1.
3. Analisis perbandingan teknik *hyperparameter tuning* yang menunjukkan bahwa metode yang digunakan lebih unggul dari metode yang lain dalam penelitian sebelumnya.

BAB V

PENUTUP

A. Kesimpulan

Dari hasil penelitian dapat disimpulkan bahwa pengaturan *hyperparameter* yang terbaik untuk model CNN *lightweight* dapat diperoleh menggunakan *framework* Optuna. Pengaturan *hyperparameter* yang tepat untuk model ShuffleNetV2, ResNet50 dan MobileNetV3 Small untuk *learning rate* ada pada 0,001, *batch size* 64 *epochs* 6 dan *optimizer* SGD. Adapun untuk model LMFRNet *learning rate* pada 0,01, *batch size* 32 *epochs* 8 dan *optimizer* SGD.

Pengaturan *hyperparameter* yang tepat menggunakan *framework* Optuna pada model CNN dapat meningkatkan kinerja model dalam mendeteksi *spoofing* wajah. Hal ini dapat ditunjukkan dengan akurasi mencapai 0,98 yang dicapai oleh model ShuffleNetV2.

B.Saran

Dalam penelitian ini *hyperparameter tuning* masih terbatas untuk dataset jenis gambar RGB. Sehingga perlu dilakukan penelitian lain terhadap pemilihan *hyperparameter* untuk mengukur kinerja model CNN dalam pendeteksian *spoofing* wajah dengan modal lain semisal infrared, *depth* atau *thermal*.

DAFTAR PUSTAKA

- Afis Julianto, Andi Sunyoto, & Ferry Wahyu Wibowo. (2022). Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi. *TEKNIMEDIA: Teknologi Informasi Dan Multimedia*, 3(2), 98–105. <https://doi.org/10.46764/teknimedia.v3i2.77>
- Agusti, H. W. N., & Gisela, B. A. (2020). Pengenalan Wajah Dengan Menggunakan Smartphone: Sistematis Review. *Journal of Indonesian Forensic and Legal Medicine*, 2(2), 156–163.
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2623–2631. <https://doi.org/10.1145/3292500.3330701>
- Alsajri, A. K. S., & Hacimahmud, A. V. (2023). Review of deep learning: Convolutional Neural Network Algorithm. *Babylonian Journal of Machine Learning*, 2023(D1), 19–25. <https://doi.org/10.58496/BJML/2023/004>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>

- Ananda, G. F., Nugroho, H. A., & Ardiyanto, I. (2024). Comparative Analysis of Multi-Face Detection Methods in Classroom Environments: Haar Cascade, MTCNN, YOLOFace, and RetinaFace. *2024 7th International Conference on Vocational Education and Electrical Engineering: Charting the Course of Artificial Technology in Sustainable Society, ICVEE 2024*, 268–273. <https://doi.org/10.1109/ICVEE63912.2024.10823781>
- Anthony, P., Ay, B., & Aydin, G. (2021). A review of face anti-spoofing methods for face recognition systems. *2021 International Conference on INnovations in Intelligent SysTems and Applications, INISTA 2021 - Proceedings, October 2022*. <https://doi.org/10.1109/INISTA52262.2021.9548404>
- Anushka Jadhav, Surabhi Lone, Sagarika Matey, Tanvi Madamwar, & Sumitra Jakhete. (2021). Survey on Face Detection Algorithms. *International Journal of Innovative Science and Research Technology*, 6(2), 291–297. www.ijisrt.com
- Asiri, A. A., Shaf, A., Ali, T., Aamir, M., Irfan, M., & Alqahtani, S. (2024). Enhancing brain tumor diagnosis: an optimized CNN hyperparameter model for improved accuracy and reliability. *PeerJ Computer Science*, 10, 1–28. <https://doi.org/10.7717/peerj-cs.1878>
- Austin, P. C., White, I. R., Lee, D. S., & van Buuren, S. (2021). Missing Data in Clinical Research: A Tutorial on Multiple Imputation. *Canadian Journal of Cardiology*, 37(9), 1322–1331. <https://doi.org/10.1016/j.cjca.2020.11.010>
- Cetinic, E., Lipic, T., & Grgic, S. (2018). Fine-tuning Convolutional Neural Networks for fine art classification. *Expert Systems with*

- Applications*, 114, 107–118.
<https://doi.org/10.1016/j.eswa.2018.07.026>
- Chavarro, A. F., Renza, D., & Ballesteros, D. M. (2023). Influence of Hyperparameters in Deep Learning Models for Coffee Rust Detection. *Applied Sciences (Switzerland)*, 13(7).
<https://doi.org/10.3390/app13074565>
- Chi, J., Kim On, C., Zhang, H., & Chai, S. S. (2023). A Review of Deep Convolutional Neural Networks in Mobile Face Recognition. *International Journal of Interactive Mobile Technologies (IJIM)*, 17(23), 4–19.
<https://doi.org/10.3991/ijim.v17i23.40867>
- Dharma, A. S., Sitorus, J. M. P., & Hatigoran, A. (2023). Comparison of Residual Network-50 and Convolutional Neural Network Conventional Architecture For Fruit Image Classification. *Sinkron*, 8(3), 1863–1874.
<https://doi.org/10.33395/sinkron.v8i3.12721>
- Farina, G. (2024). Lecture of Bayesian Optimization. *Nonlinear Optimization*, 1–7.
- Gupta, J., Pathak, S., & Kumar, G. (2022). Deep Learning (CNN) and Transfer Learning: A Review. *Journal of Physics: Conference Series*, 2273(1), 012029. <https://doi.org/10.1088/1742-6596/2273/1/012029>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>

- He, Y., & Li, T. (2020). A lightweight CNN model and its application in intelligent practical teaching evaluation. *MATEC Web of Conferences*, 309, 05016. <https://doi.org/10.1051/mateconf/202030905016>
- Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., & Azim, M. A. (2022). Transfer learning: a friendly introduction. *Journal of Big Data*, 9(1), 102. <https://doi.org/10.1186/s40537-022-00652-w>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. <http://arxiv.org/abs/1704.04861>
- Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L.-C., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Adam, H., & Le, Q. (2019). Searching for MobileNetV3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019-October, 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A Review of Deep Transfer Learning and Recent Advancements. *Technologies*, 11(2), 1–14. <https://doi.org/10.3390/technologies11020040>
- Imani, M., & Arabnia, H. R. (2023). Hyperparameter Optimization and Combined Data Sampling Techniques in Machine Learning for Customer Churn Prediction: A Comparative Analysis. *Technologies*, 11(6). <https://doi.org/10.3390/technologies11060167>
- Kalyana, S., & Buddiga, P. (2024). *The Importance of Data Cleaning in Machine Learning : Best Practices and The Importance of Data*

Cleaning in Machine Learning : Best Practices and Techniques.
January 2020.

- Liu, G., Xiao, J., & Wang, X. (2021). Optimization of Face Detection Algorithm based on MTCNN. *International Core Journal of Engineering*, 7.8, 456–464.
<https://www.icj-e.org/download/ICJE-7-8-456-464.pdf>
- Liu, Y., Jourabloo, A., & Liu, X. (2018). Learning Deep Models for Face Anti-Spoofing: Binary or Auxiliary Supervision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 389–398.
<https://doi.org/10.1109/CVPR.2018.00048>
- Ma, N., Zhang, X., Zheng, H.-T., & Sun, J. (2018). ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 11218 LNCS* (pp. 122–138).
https://doi.org/10.1007/978-3-030-01264-9_8
- Naser, O. A., Mumtazah, S., Samsudin, K., Hanafi, M., Shafie, S. M. B., & Zamri, N. Z. (2025). Comparative Analysis of MTCNN and Haar Cascades for Face Detection in Images with Variation in Yaw Poses and Facial Occlusions. *Journal of Communications Software and Systems*, 21(1), 109–119.
<https://doi.org/10.24138/jcomss-2024-0084>
- Nguyen, T. P. H., Cai, Z., Nguyen, K., Keth, S., Shen, N., & Park, M. (2020). *Pre-processing Image using Brightening, CLAHE and RETINEX*. <http://arxiv.org/abs/2003.10822>

- Perdana, R. N., Ardiyanto, I., & Nugroho, H. A. (2021). A Review on Face Anti-Spoofing. *IJITEE (International Journal of Information Technology and Electrical Engineering)*, 5(1), 29. <https://doi.org/10.22146/ijitee.61827>
- Podgorelec, V., Pečnik, Š., & Vrbančič, G. (2020). Classification of similar sports images using convolutional neural network with hyper-parameter optimization. *Applied Sciences (Switzerland)*, 10(23), 1–24. <https://doi.org/10.3390/app10238494>
- Prakash, R. M., Vimala, M., Ramalakshmi, K., Prakash, M. B., Krishnamoorthi, A., & Kumari, R. S. S. (2022). Crop Disease Detection and Classification with Transfer learning and hyper-parameters optimized Convolutional neural network. *Proceedings of the 2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies: Computational Intelligence for Smart Systems, ICICICT 2022, August*, 1608–1613. <https://doi.org/10.1109/ICICICT54557.2022.9917901>
- Prasetyo, E., Purbaningtyas, R., Dimas Adityo, R., Prabowo, E. T., Ferdiansyah, A. I., & Korespondensi, P. (2021). Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata A Comparison Of Convolution Neural Network For Classifying Milkfish's Freshness On Eye Images. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(3), 601–608. <https://doi.org/10.25126/jtiik.202184369>
- Ridzuan, F., & Wan Zainon, W. M. N. (2019). A review on data cleansing methods for big data. *Procedia Computer Science*, 161, 731–738. <https://doi.org/10.1016/j.procs.2019.11.177>

- Rodríguez, J. D., Pérez, A., & Lozano, J. A. (2010). Sensitivity Analysis of k-Fold Cross Validation in Prediction Error Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(3), 569–575. <https://doi.org/10.1109/TPAMI.2009.187>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Shen, Z. (2020). *3 min of Machine Learning: Cross Vaildation*. https://zitaoshen.rbind.io/project/machine_learning/machine-learning-101-cross-vaildation/
- Sumijan, Ayu, P., & Syafri, A. (2021). Teknologi Biometrik Impementasi pada Bidang Medis Menggunakan Matlabs. In *Teknologi Biometrik*.
- Taner, A., Öztekin, Y. B., & Duran, H. (2021). Performance Analysis of Deep Learning CNN Models for Variety Classification in Hazelnut. *Sustainability*, 13(12), 6527. <https://doi.org/10.3390/su13126527>
- Victoria, A. H., & Maragatham, G. (2021). Automatic tuning of hyperparameters using Bayesian optimization. *Evolving Systems*, 12(1), 217–223. <https://doi.org/10.1007/s12530-020-09345-2>
- Wan, G., & Yao, L. (2023). LMFRNet: A Lightweight Convolutional Neural Network Model for Image Analysis. *Electronics*, 13(1), 129. <https://doi.org/10.3390/electronics13010129>

- Wang, X., Jin, Y., Schmitt, S., & Olhofer, M. (2023). Recent Advances in Bayesian Optimization. In *ACM Computing Surveys* (Vol. 55, Issue 13s). Association for Computing Machinery. <https://doi.org/10.1145/3582078>
- Wanto, A., Yuhandri, Y., & Okfalisa, O. (2023). Optimization Accuracy of CNN Model by Utilizing CLAHE Parameters in Image Classification Problems. *Proceedings - 2023 International Conference on Networking, Electrical Engineering, Computer Science, and Technology, IConNECT 2023*, 253–258. <https://doi.org/10.1109/IConNECT56593.2023.10327100>
- Xie, Y. G., Wang, H., & Guo, S. H. (2020). Research on MTCNN Face Recognition System in Low Computing Power Scenarios. *Journal of Internet Technology*. <https://jit.ndhu.edu.tw/article/view/2380>
- Yu, Z., Qin, Y., Li, X., Zhao, C., Lei, Z., & Zhao, G. (2023). Deep Learning for Face Anti-Spoofing: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(5), 5609–5631. <https://doi.org/10.1109/TPAMI.2022.3215850>
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6848–6856. <https://doi.org/10.1109/CVPR.2018.00716>