



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Pengembangan Sistem Smart Lighting Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision

SKRIPSI

MUHAMAD ADNAN FADILLAH

2207411048

**POLITEKNIK
NEGERI
JAKARTA**

**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK INFORMATIKA DAN
KOMPUTER
POLITEKNIK NEGERI JAKARTA
2026**



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Pengembangan Sistem Smart Lighting Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision

SKRIPSI

**Dibuat untuk Melengkapi Syarat-Syarat yang Diperlukan untuk
Memperoleh Diploma Empat Politeknik**

MUHAMAD ADNAN FADILLAH

2207411048

**POLITEKNIK
NEGERI
JAKARTA**

**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK INFORMATIKA DAN KOMPUTER
POLITEKNIK NEGERI JAKARTA**

2026



SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertanda tangan di bawah ini:

Nama : Muhamad Adnan Fadillah
NIM : 2207411048
Jurusan/Program Studi : T.Informatika dan Komputer / Teknik Informatika
Judul Skripsi : Pengembangan Sistem Smart Lighting Indoor Berbasis
Klasifikasi Aktivitas Manusia Menggunakan Computer
Vision

Menyatakan dengan sebenarnya bahwa skripsi ini benar-benar merupakan hasil karya saya sendiri, bebas dari peniruan terhadap karya dari orang lain. Kutipan pendapat dan tulisan orang lain ditunjuk sesuai dengan cara-cara penulisan karya ilmiah yang berlaku.

Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa dalam skripsi ini terkandung ciri-ciri plagiat dan bentuk-bentuk peniruan lain yang dianggap melanggar peraturan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Depok, 10 Juni 2026

Yang membuat pernyataan


91C35AOX108539928
METERAI TEMPEL

Muhamad Adnan Fadillah

NIM 2207411048

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta

2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun

tanpa izin Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta

2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun

LEMBAR PENGESAHAN

Skripsi diajukan oleh :

Nama : Muhamad Adnan Fadillah

NIM : 2207411048

Program Studi : Teknik Informatika

Judul Skripsi : Pengembangan Sistem Smart Lighting Indoor
: Berbasis Klasifikasi Aktivitas Manusia
Menggunakan Computer Vision

Telah diuji oleh tim penguji dalam Sidang Skripsi pada hari Selasa,

Tanggal 23, Bulan Juni, Tahun 2026 dan dinyatakan **LULUS**.

Disahkan oleh

Pembimbing I : Rizki Elisa Nalawati, S.T., M.T. (.....)

Penguji I : Euis Oktavianti, S.Si., M.T.I. (.....)

Penguji II : Susana Dwi Yulianti, M.Kom. (.....)

Penguji III : Anggi Mardiyono, S.Kom., M.Kom. (.....)

Mengetahui :

Jurusan Teknik Informatika dan Komputer

Ketua



Dr. Anita Hidayati, S.Kom., M.Kom..

NIP 197908032003122003



Hak Cipta:

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

KATA PENGANTAR

Puji syukur dipanjatkan ke hadirat Allah Swt. atas limpahan rahmat dan karunia-Nya sehingga skripsi yang berjudul "Pengembangan Sistem Smart Lighting Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision" ini dapat diselesaikan dengan baik sebagai salah satu syarat untuk menyelesaikan pendidikan Program Sarjana Terapan (D4) pada Program Studi Teknik Informatika, Jurusan Teknik Informatika dan Komputer, Politeknik Negeri Jakarta. Dalam proses penyusunannya, banyak bantuan, bimbingan, dan dukungan yang diterima dari berbagai pihak, sehingga ucapan terima kasih yang sebesar-besarnya disampaikan kepada:

1. Ibu Rizki Elisa Nalawati, S.T., M.T., selaku Dosen Pembimbing yang telah meluangkan waktu, tenaga, dan pikirannya untuk memberikan bimbingan, arahan, dan masukan yang sangat berharga selama proses penyusunan skripsi ini.
2. Kedua orang tua yang senantiasa memberikan doa, dukungan moral, dan semangat yang tiada henti selama menempuh pendidikan.
3. Seluruh rekan mahasiswa Program Studi Teknik Informatika angkatan 2022 yang telah memberikan semangat dan bantuan selama proses pengerjaan skripsi ini.

Disadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran yang membangun dari semua pihak sangat diharapkan demi perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi perkembangan ilmu pengetahuan dan teknologi, khususnya di bidang *computer vision* dan sistem otomasi cerdas.

Depok, 10 Juni 2026

Muhamad Adnan Fadillah

NIM 2207411048



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta:

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta

2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

SURAT PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Politeknik Negeri Jakarta, saya bertanda tangan dibawah ini :

Nama : Muhamad Adnan Fadillah

NIM : 2207411048

Jurusan/Program Studi : T.Informatika dan Komputer / Teknik Informatika

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Politeknik Negeri Jakarta Hak Bebas Royalti Non-Eksklusif atas karya ilmiah saya yang berjudul :

Pengembangan Sistem Smart Lighting Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksklusif ini Politeknik Negeri Jakarta Berhak menyimpan, mengalihmediakan/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan skripsi saya tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Depok, 10 Juni 2026

Yang Menyatakan




Muhamad Adnan Fadillah

NIM 2207411048



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pengembangan Sistem Smart Lighting Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision

ABSTRAK

Sistem pencahayaan kamar tidur yang masih dikendalikan secara manual atau berbasis sensor konvensional belum mampu merespons kondisi ruangan secara kontekstual berdasarkan aktivitas spesifik penghuni. Penelitian ini mengembangkan sistem smart lighting indoor berbasis computer vision dengan pendekatan rule-based yang mengintegrasikan klasifikasi aktivitas manusia dan deteksi kecerahan cahaya ruangan untuk mengendalikan lampu secara otomatis. Sistem dirancang dengan pipeline: akuisisi citra oleh kamera Tapo C200, inferensi model MobileNetV2 untuk mengklasifikasikan empat kelas aktivitas (empty_room, lying_down, sitting, standing), pengambilan keputusan berbasis aturan IF-THEN yang mempertimbangkan hasil klasifikasi dan nilai sensor LDR, serta eksekusi kondisi lampu melalui mikrokontroler ESP32. Sebagai perbandingan, pendekatan machine learning berbasis HOG+SVM juga diimplementasikan dan dievaluasi. Hasil evaluasi menunjukkan model MobileNetV2 mencapai akurasi 95,41% pada data uji, jauh melampaui HOG+SVM yang hanya mencapai 69,28% dengan indikasi overfitting. Pengujian pada kondisi real-world menghasilkan akurasi 90,00%, melampaui target minimum 85%. Logika rule-based berjalan sesuai ekspektasi pada 87,5% skenario yang diuji, dan seluruh komponen sistem terintegrasi secara fungsional dari kamera hingga aktuator lampu.

Kata Kunci: *computer vision, deep learning, ESP32, MobileNetV2, rule-based, sensor LDR, smart lighting, support vector machine, transfer learning*

POLITEKNIK
NEGERI
JAKARTA



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR ISI

SURAT PERNYATAAN BEBAS PLAGIARISME	ii
LEMBAR PENGESAHAN	iii
KATA PENGANTAR.....	iv
SURAT PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK KEPENTINGAN AKADEMIS.....	v
ABSTRAK	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	x
DAFTAR TABEL.....	xi
BAB I PENDAHULUAN	12
1.1 Latar Belakang Masalah.....	12
1.2 Perumusan Masalah	13
1.3 Batasan Masalah.....	14
1.4 Tujuan dan Manfaat	15
1.4.1 Tujuan.....	15
1.4.2 Manfaat	15
1.5 Sistematika Penulisan	16
BAB II TINJAUAN PUSTAKA.....	18
2.1 Tinjauan Pustaka	18
2.2 Landasan Teori	21
2.2.1 <i>Smart Lighting Indoor</i>	21
2.2.2 Convolutional Neural Network (CNN).....	22
2.2.3 MobileNetV2	22
2.2.4 <i>Transfer learning</i>	23
2.2.5 Histogram of Oriented Gradients (HOG).....	24
2.2.6 Local Binary Pattern	25
2.2.7 Support Vector Machine.....	25



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2.2.8	Sistem Berbasis Aturan (<i>Rule-Based System</i>).....	26
2.2.9	Grad-CAM (Gradient-weighted Class Activation Mapping).....	27
2.2.10	Metrik Evaluasi	28
BAB III METODE PENELITIAN.....		30
3.1	Rancangan Penelitian	30
3.2	Tahapan Penelitian	30
3.3	Objek Penelitian	35
BAB IV HASIL DAN PEMBAHASAN.....		37
4.1	Analisis Kebutuhan	37
4.1.1	Kebutuhan Fungsional	37
4.1.2	Kebutuhan Non-Fungsional	38
4.1.3	Spesifikasi Perangkat	39
4.2	Perancangan Sistem	40
4.2.1	Arsitektur <i>Pipeline</i> Sistem	40
4.2.2	Topologi Jaringan	41
4.2.3	Perancangan <i>Rule-based Decision</i>	43
4.2.4	Konfigurasi Perangkat Keras ESP32	45
4.3	Implementasi Sistem	47
4.3.1	Konstruksi <i>Dataset</i>	47
4.3.2	Perbandingan Pendekatan <i>Machine learning</i> dan <i>Deep learning</i> .	48
4.3.3	Penanganan <i>Domain gap</i> dengan Data Domain-Specific	52
4.3.4	Eksperimen <i>Fine-tuning</i> dengan <i>Dataset</i> Gabungan (NB1-NB4)	56
4.3.5	Analisis Perbandingan Strategi <i>Transfer learning</i>	60
4.3.6	Explainable AI: Analisis Grad-CAM	62
4.3.7	Implementasi Integrasi IoT	64
4.4	Pengujian.....	67
4.4.1	Deskripsi Pengujian	67
4.4.2	Prosedur Pengujian	67
4.4.3	Data Hasil Pengujian.....	69
4.4.4	Analisis dan Evaluasi Pengujian	74



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB V PENUTUP.....	79
5.1 Simpulan	79
5.2 Saran.....	80
DAFTAR PUSTAKA	82
DAFTAR RIWAYAT HIDUP.....	84





Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR GAMBAR

Gambar 3.1 Diagram Alur Rancangan Penelitian	31
Gambar 3.2 Arsitektur Pipeline Sistem Smart lighting indoor	34
Gambar 4.1 Arsitektur Pipeline Sistem.....	41
Gambar 4.2 Topologi Jaringan Sistem	42
Gambar 4.3 Diagram Pohon Keputusan Rule-based.....	44
Gambar 4.4 Flowchart Rule-based Decision	45
Gambar 4.5 Skema Rangkaian Perangkat Keras ESP32.....	46
Gambar 4.6 Grafik Perbandingan Akurasi SVM vs MobileNetV2 per Kelas	52
Gambar 4.7 Antarmuka Sesi Perekam Dataset Tapo.....	54
Gambar 4.8 Sampel Frame Dataset Domain Specific Tapo_Record_Wall per Kelas	56
Gambar 4.9 Grafik Perbandingan Akurasi NB1-NB4	58
Gambar 4.10 Training History NB3 (Finetune Full).....	58
Gambar 4.11 Confusion matrix Model NB3 (Model Final).....	60
Gambar 4.12 Training History Feature Extraction Only.....	61
Gambar 4.13 Confusion matrix Feature Extraction Only	62
Gambar 4.14 Hasil Grad-CAM per Kelas Model NB3.....	63
Gambar 4.15 Foto Implementasi Perangkat Keras Sistem.....	66
Gambar 4.16 Contoh Output Sistem untuk Setiap Kelas Aktivitas	70
Gambar 4.17 Foto Pengujian 2: Simulasi Kondisi LDR.....	72
Gambar 4.18 Foto Pengujian 3: Sistem Berjalan End-to-end.....	74
Gambar 4.19 Grafik Akurasi per Kelas: Pengujian Real World vs Test Set	78



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR TABEL

Tabel 1 Penelitian Terdahulu.....	18
Tabel 2 Kebutuhan Fungsional Sistem.....	37
Tabel 3 Kebutuhan Non-Fungsional Sistem	38
Tabel 4 Spesifikasi Perangkat	39
Tabel 5 Konfigurasi Server dan Perangkat Komputasi	43
Tabel 6 Rule-based Decision.....	44
Tabel 7 Konfigurasi Pin ESP32.....	46
Tabel 8 Distribusi Dataset HAR Indoor (Kurasi).....	48
Tabel 9 Perbandingan Keseluruhan SVM vs MobileNetV2	49
Tabel 10 Classification Report per Kelas SVM	49
Tabel 11 Classification Report per Kelas MobileNetV2.....	51
Tabel 12 Distribusi Dataset Domain-Specific Tapo_Record_Wall.....	55
Tabel 13 Rangkuman Hasil Eksperimen NB1-NB4.....	57
Tabel 14 Classification Report Model NB3 (Model Final).....	59
Tabel 15 Perbandingan Strategi Feature Extraction Only dan Fine-tune.....	61
Tabel 16 Deskripsi Pengujian Sistem.....	67
Tabel 17 Prosedur Pengujian 1	68
Tabel 18 Prosedur Pengujian 2.....	68
Tabel 19 Prosedur Pengujian 3.....	69
Tabel 20 Hasil Pengujian 1 Akurasi Model CV per Kelas.....	69
Tabel 21 Confusion matrix Pengujian 1 (Real-world).....	70
Tabel 22 Hasil Pengujian 2 Observasi Rule-based Decision	71
Tabel 23 Hasil Pengujian Integrasi End-to-end	73
Tabel 24 Ringkasan Hasil Pengujian Keseluruhan	77



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB I PENDAHULUAN

1.1 Latar Belakang Masalah

Perkembangan teknologi otomasi rumah (*home automation*) telah mendorong munculnya berbagai solusi sistem pencahayaan yang lebih cerdas dan adaptif. Salah satu tantangan utama dalam implementasinya adalah bagaimana sistem pencahayaan dapat merespons kondisi ruangan secara otomatis dan kontekstual, tanpa bergantung sepenuhnya pada interaksi manual pengguna. Beberapa penelitian terkait sistem otomasi dan *smart lighting* menunjukkan bahwa pengendalian pencahayaan yang tidak adaptif terhadap kondisi ruangan dapat menurunkan kenyamanan penghuni sekaligus mengurangi efektivitas penggunaan sistem pencahayaan itu sendiri (Atmaja, Sari and Ciptadi, 2021; Al-Hafiz *et al.*, 2025).

Pada praktiknya, sistem pencahayaan kamar tidur umumnya masih dikendalikan secara manual atau semi-otomatis. Penggunaan sakelar konvensional menyebabkan kondisi lampu sepenuhnya bergantung pada kebiasaan pengguna, tanpa mempertimbangkan kondisi aktual ruangan. Literatur terkait sistem pencahayaan berbasis IoT dan otomasi menunjukkan bahwa pendekatan manual seperti ini rentan terhadap kelalaian pengguna, terutama ketika penghuni meninggalkan ruangan tanpa mematikan lampu (Muhammad Zikri, Muhammad Fikry and Rizki Suwanda, 2025).

Permasalahan tersebut menjadi semakin penting mengingat sistem pencahayaan otomatis yang telah ada pun masih memiliki keterbatasan. Beberapa penelitian sebelumnya mengusulkan sistem berbasis sensor cahaya atau sensor gerak, namun pendekatan tersebut belum sepenuhnya mampu merepresentasikan kondisi penggunaan ruangan secara kontekstual, khususnya dalam memahami keberadaan dan aktivitas manusia secara spesifik. Hal ini diperkuat oleh hasil wawancara terhadap beberapa pengguna kamar tidur, di mana pengguna pernah lupa mematikan lampu saat meninggalkan ruangan dan menilai sistem pencahayaan yang ada belum cukup adaptif karena belum mampu menyesuaikan kondisi lampu berdasarkan keberadaan penghuni sekaligus tingkat kecerahan cahaya di dalam ruangan (Al-Hafiz *et al.*, 2025).



Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pengembangan sistem *smart lighting indoor* berbasis *computer vision* dengan mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*). Sistem dirancang dengan memanfaatkan kamera sebagai sensor utama untuk mendeteksi keberadaan dan aktivitas spesifik manusia, serta sensor cahaya (LDR) sebagai modul terpisah untuk mendeteksi tingkat kecerahan cahaya ruangan. Dalam rangka memilih metode deteksi aktivitas yang paling optimal, penelitian ini membandingkan dua pendekatan klasifikasi, yaitu pendekatan *machine learning* berbasis Histogram of Oriented Gradients (HOG) dengan Support Vector Machine (SVM), serta pendekatan *deep learning* menggunakan arsitektur MobileNetV2. Hasil evaluasi menunjukkan bahwa model MobileNetV2 menghasilkan akurasi yang lebih tinggi secara signifikan dibandingkan pendekatan HOG+SVM, sehingga dipilih sebagai model final dalam sistem. Dengan demikian, penelitian ini berkontribusi dalam menghadirkan sistem pencahayaan *indoor* yang lebih adaptif dan kontekstual dibandingkan pendekatan berbasis sensor konvensional, sekaligus memberikan evaluasi komparatif antara pendekatan *machine learning* dan *deep learning* pada domain klasifikasi aktivitas manusia untuk keperluan otomasi ruangan.

1.2 Perumusan Masalah

1. Bagaimana merancang sistem *smart lighting indoor* berbasis *computer vision* yang mampu mendeteksi keberadaan dan aktivitas spesifik manusia di dalam kamar tidur menggunakan kamera sebagai sensor utama?
2. Bagaimana membandingkan performa pendekatan *machine learning* berbasis Histogram of Oriented Gradients (HOG) dengan Support Vector Machine (SVM) dan pendekatan *deep learning* menggunakan arsitektur MobileNetV2 dalam klasifikasi aktivitas manusia untuk keperluan sistem *smart lighting indoor*?
3. Bagaimana mendeteksi tingkat kecerahan cahaya ruangan menggunakan sensor cahaya (LDR) sebagai modul terpisah yang mendukung pengambilan keputusan sistem pencahayaan?

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4. Bagaimana mengintegrasikan hasil klasifikasi aktivitas manusia dan tingkat kecerahan cahaya ruangan ke dalam mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*)?
5. Bagaimana kinerja sistem *smart lighting indoor* yang dikembangkan dalam mengendalikan pencahayaan kamar tidur secara adaptif berdasarkan kombinasi deteksi aktivitas manusia dan tingkat kecerahan cahaya ruangan?

1.3 Batasan Masalah

1. Penelitian ini dibatasi pada pengembangan sistem *smart lighting indoor* berbasis *computer vision* yang diterapkan pada kamar tidur sebagai ruang uji penelitian.
2. Klasifikasi aktivitas manusia pada sistem dibatasi pada empat kelas aktivitas, yaitu *empty_room*, *lying_down*, *sitting*, dan *standing*, tanpa melakukan pengenalan identitas individu.
3. Perbandingan metode klasifikasi aktivitas dibatasi pada dua pendekatan, yaitu *machine learning* berbasis Histogram of Oriented Gradients (HOG) dengan Support Vector Machine (SVM), dan *deep learning* menggunakan arsitektur MobileNetV2.
4. *Dataset* yang digunakan dalam pelatihan dan pengujian model klasifikasi aktivitas adalah *dataset* yang dikonstruksi secara mandiri dengan total sekitar 3.610 gambar yang terbagi dalam empat kelas aktivitas dengan rasio pembagian data latih dan data uji sebesar 80:20.
5. Deteksi tingkat kecerahan cahaya ruangan dilakukan menggunakan sensor cahaya (LDR) sebagai modul terpisah yang berfungsi sebagai pendukung pengambilan keputusan, tanpa melakukan analisis kecerahan berbasis kamera.
6. Mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*) dibatasi pada sekumpulan aturan IF-THEN statis yang diimplementasikan pada firmware mikrokontroler ESP32, dengan masukan berupa hasil klasifikasi aktivitas dari model *computer vision* dan nilai pembacaan sensor cahaya (LDR), serta keluaran berupa tiga kondisi pencahayaan (lampu



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

menyala, mati, atau redup) pada satu titik lampu, tanpa mekanisme pembelajaran atau pembaruan aturan secara otomatis.

7. Pengujian sistem dilakukan pada skenario kamar tidur sebagai ruang uji terbatas dan tidak mencakup implementasi pada gedung berskala besar atau sistem manajemen bangunan terintegrasi.

1.4 Tujuan dan Manfaat

1.4.1 Tujuan

Tujuan dari penelitian ini adalah sebagai berikut:

1. Merancang sistem *smart lighting indoor* berbasis *computer vision* yang mampu mendeteksi keberadaan dan aktivitas spesifik manusia di dalam kamar tidur menggunakan kamera sebagai sensor utama.
2. Membandingkan performa pendekatan *machine learning* berbasis Histogram of Oriented Gradients (HOG) dengan Support Vector Machine (SVM) dan pendekatan *deep learning* menggunakan arsitektur MobileNetV2 dalam klasifikasi aktivitas manusia untuk keperluan sistem *smart lighting indoor*.
3. Mendeteksi tingkat kecerahan cahaya ruangan menggunakan sensor cahaya (LDR) sebagai modul terpisah yang mendukung pengambilan keputusan sistem pencahayaan.
4. Mengintegrasikan hasil klasifikasi aktivitas manusia dan tingkat kecerahan cahaya ruangan ke dalam mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*).
5. Mengevaluasi kinerja sistem *smart lighting indoor* yang dikembangkan dalam mengendalikan pencahayaan kamar tidur secara adaptif berdasarkan kombinasi deteksi aktivitas manusia dan tingkat kecerahan cahaya ruangan.

1.4.2 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

1. Membantu penghuni ruangan mengendalikan pencahayaan kamar tidur secara otomatis dan adaptif sesuai aktivitas yang sedang dilakukan, tanpa perlu mengoperasikan sakelar lampu secara manual.
2. Membantu mengurangi potensi pemborosan energi listrik karena lampu dimatikan secara otomatis ketika ruangan tidak berpenghuni atau ketika tingkat kecerahan cahaya ruangan telah mencukupi.
3. Menyesuaikan tingkat pencahayaan dengan kebutuhan istirahat penghuni, seperti meredupkan lampu secara otomatis ketika penghuni berbaring, sehingga mendukung kenyamanan penggunaan ruangan.

1.5 Sistematika Penulisan

BAB I PENDAHULUAN

Bab ini berisi gambaran umum mengenai penelitian yang dilakukan, meliputi latar belakang masalah, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan. Bab ini bertujuan untuk memberikan pemahaman awal mengenai arah dan ruang lingkup penelitian.

BAB II TINJAUAN PUSTAKA

Bab ini membahas landasan teori dan penelitian terdahulu yang relevan dengan topik penelitian. Pembahasan meliputi konsep *smart lighting indoor*, *computer vision*, klasifikasi aktivitas manusia berbasis kamera, pendekatan *machine learning* menggunakan Histogram of Oriented Gradients (HOG) dengan Support Vector Machine (SVM), pendekatan *deep learning* menggunakan arsitektur MobileNetV2, serta konsep pengambilan keputusan berbasis aturan (*rule-based decision*), teknik *Gradient-weighted Class Activation Mapping* (Grad-CAM) untuk interpretasi model, dan metrik evaluasi yang digunakan dalam penelitian ini. Pada bab ini juga disajikan kerangka pemikiran penelitian sebagai dasar perancangan sistem *smart lighting indoor* yang dikembangkan.

BAB III METODE PENELITIAN

Bab ini menjelaskan metode penelitian yang digunakan dalam penelitian ini. Pembahasan meliputi rancangan penelitian yang digunakan, tahapan penelitian mulai dari identifikasi masalah hingga pengujian sistem, serta objek penelitian yang

mencakup komponen utama sistem *smart lighting indoor* berbasis *computer vision* yang dikembangkan.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil penelitian beserta pembahasannya secara menyeluruh. Pembahasan meliputi analisis kebutuhan fungsional dan non-fungsional serta spesifikasi perangkat, perancangan sistem yang mencakup arsitektur *pipeline*, topologi jaringan, dan mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*), implementasi sistem yang meliputi konstruksi *dataset*, perbandingan pendekatan *machine learning* (HOG+SVM) dan *deep learning* (MobileNetV2), penanganan *domain gap*, eksperimen *fine-tuning* dengan *dataset* gabungan, analisis *explainable AI* menggunakan Grad-CAM, serta integrasi IoT, dan diakhiri dengan hasil pengujian kinerja sistem *smart lighting indoor* secara keseluruhan pada skenario kamar tidur.

BAB V PENUTUP

Bab ini berisi simpulan dari hasil penelitian yang telah dilakukan serta saran untuk pengembangan lebih lanjut. Simpulan disusun berdasarkan hasil evaluasi komparatif metode dan kinerja sistem *smart lighting indoor* yang dikembangkan.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Tinjauan terhadap penelitian-penelitian terdahulu dilakukan untuk mengidentifikasi kesenjangan penelitian (*research gap*) serta memetakan posisi penelitian ini di antara karya-karya yang telah ada. Penelitian yang ditinjau mencakup topik-topik yang relevan, meliputi sistem *smart lighting* berbasis sensor IoT, sistem otomasi berbasis pendekatan *rule-based*, deteksi kehadiran dan aktivitas manusia dalam ruangan, serta penerapan *transfer learning* dalam klasifikasi citra. Ringkasan penelitian terdahulu beserta persamaan dan perbedaannya dengan penelitian ini disajikan pada Tabel 1.

Tabel 1 Penelitian Terdahulu

Peneliti (Tahun)	Judul	Metode	Hasil	Persamaan	Perbedaan
(Atmaja, Sari and Ciptadi, 2021)	Developing application of automatic lamp control and monitoring system using internet of things	IoT, sensor PIR + LDR, relay, Wemos D1 (ESP8266), Firebase	Sistem berhasil mengontrol lampu secara otomatis berdasarkan kehadiran dan intensitas cahaya	Sistem smart lighting, sensor LDR, relay sebagai aktuator lampu	Tidak menggunakan <i>computer vision</i> ; deteksi kehadiran menggunakan sensor PIR, bukan kamera; tidak ada klasifikasi aktivitas spesifik; tidak menerapkan pendekatan <i>rule-based</i> berbasis aktivitas
(Al-Hafiz et al., 2025)	Implementasi <i>Smart lighting</i> Berbasis Sensor Cahaya dan Sensor Air untuk Respon Lingkungan Berbasis Arduino Uno	Arduino Uno, sensor LDR, sensor air, relay	Sistem berhasil mengendalikan lampu secara otomatis berdasarkan tingkat kecerahan cahaya dari sensor LDR	Sistem <i>smart lighting</i> , sensor LDR sebagai pendeteksi cahaya, relay sebagai aktuator	Tidak menggunakan <i>computer vision</i> ; tidak ada klasifikasi aktivitas manusia; platform mikrokontroler Arduino Uno, bukan ESP32; tidak menerapkan pendekatan <i>rule-</i>



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Peneliti (Tahun)	Judul	Metode	Hasil	Persamaan	Perbedaan
					<i>based</i> berbasis aktivitas
(Muhamad Zikri, Muhammad Fikry and Rizki Suwanda, 2025)	Rancang Bangun Smart Greenhouse Otomatis Berbasis IoT dengan Kontrol Rule-Based pada Budidaya Tanaman Tomat	<i>Rule-based</i> , ESP32, sensor LDR, DHT22, platform Blynk	Sistem <i>rule-based</i> berhasil mengontrol perangkat aktuator greenhouse secara otomatis berdasarkan kondisi lingkungan	Pendekatan <i>rule-based</i> dengan logika IF-THEN, penggunaan mikrokontroler ESP32, sensor LDR sebagai masukan kondisi	Domain aplikasi greenhouse/pertanian, bukan <i>smart lighting indoor</i> ; tidak menggunakan <i>computer vision</i> ; tidak ada klasifikasi aktivitas manusia
(Anggono <i>et al.</i> , 2025)	Sistem Deteksi Kehadiran Manusia dalam Ruang Menggunakan Algoritma Histogram of Oriented Gradients	HOG + SVM, klasifikasi biner kehadiran manusia <i>indoor</i>	Akurasi deteksi terbaik mencapai 66%	Deteksi kehadiran manusia dalam ruangan, penggunaan HOG+SVM sebagai metode klasifikasi berbasis citra	Hanya mendeteksi kehadiran (biner: ada/tidak ada), bukan klasifikasi empat kelas aktivitas spesifik; tidak ada integrasi IoT maupun sistem kontrol lampu; tidak menerapkan <i>deep learning</i>
(Muhammad Malik Matin <i>et al.</i> , 2026)	<i>Transfer learning</i> untuk Deteksi Status Burung di Indonesia Berbasis Web	<i>Transfer learning</i> (MobileNetV3Small, MobileNetV3Large, VGG16, InceptionV4), backend FastAPI	MobileNetV3Large menghasilkan performa terbaik dengan akurasi 96,52%, <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> masing-masing 0,97	Pendekatan <i>transfer learning</i> untuk klasifikasi citra, penggunaan FastAPI sebagai backend inferensi, evaluasi menggunakan metrik akurasi, presisi, <i>recall</i> , dan <i>F1-score</i>	Domain klasifikasi spesies burung, bukan aktivitas manusia <i>indoor</i> ; tidak ada integrasi IoT; tidak ada mekanisme <i>rule-based</i> ; arsitektur model MobileNetV3, bukan MobileNetV2

Beberapa penelitian terdahulu telah mengkaji pengembangan sistem *smart lighting* berbasis IoT. (Atmaja, Sari and Ciptadi, 2021) mengembangkan sistem kontrol



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

lampu otomatis menggunakan sensor PIR dan LDR yang dihubungkan ke platform Firebase melalui Wemos D1, dan berhasil mendemonstrasikan fungsionalitas pengendalian lampu secara nirkabel. Senada dengan hal tersebut, (Al-Hafiz *et al.*, 2025) mengimplementasikan sensor LDR pada platform Arduino Uno untuk mengontrol lampu berdasarkan tingkat kecerahan cahaya ruangan. Kedua penelitian tersebut memiliki persamaan dengan penelitian ini dalam hal pemanfaatan sensor LDR dan relay sebagai komponen pengendalian lampu, namun keduanya belum mengintegrasikan mekanisme deteksi aktivitas manusia secara kontekstual, sehingga respons sistem masih bersifat reaktif terhadap satu jenis sensor tunggal tanpa mempertimbangkan konteks penggunaan ruangan secara spesifik.

Pada aspek pendekatan *rule-based*, (Muhammad Zikri, Muhammad Fikry and Rizki Suwanda, 2025) bahwa logika IF-THEN berbasis sensor dapat diterapkan secara efektif pada sistem otomasi menggunakan ESP32, meskipun dalam konteks greenhouse pertanian. Penelitian tersebut menjadi rujukan dalam perancangan mekanisme pengambilan keputusan pada penelitian ini, khususnya dalam hal struktur aturan dan integrasi sensor lingkungan dengan mikrokontroler ESP32. Perbedaan mendasar terletak pada sumber masukan aturan: penelitian (Muhammad Zikri, Muhammad Fikry and Rizki Suwanda, 2025) mengandalkan sensor suhu dan kelembapan, sedangkan penelitian ini mengintegrasikan keluaran model *computer vision* sebagai masukan utama logika *rule-based*.

Dari sisi pendekatan *computer vision*, (Anggono *et al.*, 2025) melakukan deteksi kehadiran manusia dalam ruangan menggunakan HOG+SVM dan memperoleh akurasi terbaik sebesar 66%. Penelitian tersebut memperlihatkan keterbatasan pendekatan *machine learning* berbasis fitur handcrafted dalam menangkap representasi visual yang kompleks pada lingkungan *indoor*. Hal ini memperkuat justifikasi penggunaan pendekatan *deep learning* berbasis MobileNetV2 dalam penelitian ini, yang memperoleh akurasi 69,28% pada metode HOG+SVM sebagai *baseline* dan 95,21% pada MobileNetV2 pada data uji, serta menunjukkan bahwa kualitas fitur merupakan faktor penentu yang lebih kritis dibandingkan pemilihan pengklasifikasi. Selain itu, penelitian (Anggono *et al.*, 2025) tidak



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

mengintegrasikan hasil deteksi ke dalam sistem kontrol aktuator, sehingga belum membentuk sistem otomasi yang utuh.

Pada aspek *transfer learning*, (Muhamad Malik Matin *et al.*, 2026) membuktikan efektivitas pendekatan ini dalam klasifikasi citra pada domain spesies burung Indonesia, dengan MobileNetV3Large sebagai model terbaik yang mencapai akurasi 96,52% menggunakan FastAPI sebagai *backend* inferensi. Penelitian tersebut memiliki kemiripan metodologis dengan penelitian ini dalam hal penggunaan *transfer learning* dan FastAPI, namun berbeda secara substansial pada domain aplikasi dan tujuan sistem. Penelitian ini menggunakan MobileNetV2 untuk klasifikasi empat kelas aktivitas manusia *indoor* dan mengintegrasikan keluaran model secara langsung ke dalam sistem IoT berbasis ESP32 untuk pengendalian pencahayaan ruangan.

Berdasarkan tinjauan di atas, dapat diidentifikasi kesenjangan penelitian yang menjadi landasan penelitian ini: belum ada penelitian yang mengintegrasikan *computer vision* berbasis *deep learning* dengan mekanisme *rule-based decision* dan sistem IoT dalam satu *pipeline* untuk pengendalian pencahayaan *indoor* secara kontekstual berdasarkan klasifikasi aktivitas spesifik manusia. Penelitian ini hadir untuk mengisi kesenjangan tersebut.

2.2 Landasan Teori

2.2.1 *Smart Lighting Indoor*

Smart lighting indoor merupakan sistem pencahayaan yang dirancang untuk merespons kondisi lingkungan secara otomatis tanpa memerlukan intervensi manual dari pengguna. Komponen utama yang umumnya digunakan dalam sistem *smart lighting* mencakup sensor cahaya (LDR) sebagai pendeteksi tingkat kecerahan ruangan, aktuator berupa relay atau dimmer sebagai pengendali lampu, serta mikrokontroler sebagai unit pemrosesan logika kontrol (Atmaja, Sari and Ciptadi, 2021).

Penerapan *smart lighting berbasis* sensor konvensional telah dibuktikan mampu mengotomasi pengendalian lampu berdasarkan intensitas cahaya yang terdeteksi sensor LDR (Al-Hafiz *et al.*, 2025). Meskipun demikian, pendekatan berbasis



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

sensor tunggal ini memiliki keterbatasan mendasar: sistem hanya mampu mendeteksi ada atau tidaknya cahaya, tanpa memahami konteks aktivitas penghuni di dalam ruangan. Keterbatasan tersebut menjadi motivasi utama pengintegrasian *computer vision* dalam penelitian ini, sehingga sistem mampu menyesuaikan kondisi lampu tidak hanya berdasarkan intensitas cahaya, tetapi juga berdasarkan klasifikasi aktivitas spesifik manusia yang terdeteksi oleh kamera.

2.2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang dirancang untuk pengolahan data berbentuk citra, dengan kemampuan mengekstraksi fitur secara hierarkis melalui susunan lapisan konvolusi dan pooling (Gulzar, 2023). Lapisan utama yang menyusun CNN meliputi: lapisan konvolusi (*convolutional layer*) yang menerapkan filter/*kernel* untuk mendeteksi pola lokal pada citra; fungsi aktivasi ReLU (*Rectified Linear Unit*) yang memperkenalkan nonlinearitas pada hasil konvolusi; lapisan pooling yang mereduksi dimensi spasial fitur; serta lapisan fully connected yang mengasosiasikan representasi fitur dengan label kelas (Duklan *et al.*, 2024).

Keunggulan utama CNN dibandingkan metode klasifikasi citra konvensional adalah kemampuannya mempelajari representasi fitur secara otomatis dari data latih, tanpa memerlukan rekayasa fitur manual (*feature engineering*). Hal ini menjadikan CNN lebih adaptif terhadap variasi kompleks dalam data citra (Gulzar, 2023). Berbagai arsitektur CNN modern telah dikembangkan berdasarkan fondasi ini, di antaranya AlexNet, VGG16, ResNet, InceptionV3, dan MobileNetV2. Berdasarkan studi komparatif yang dilakukan oleh (Duklan *et al.*, 2024), MobileNetV2 menunjukkan keunggulan dalam efisiensi memori dibandingkan arsitektur lain yang diuji, sehingga menjadikannya pilihan yang tepat untuk skenario inferensi dengan sumber daya komputasi terbatas.

2.2.3 MobileNetV2

MobileNetV2 merupakan arsitektur CNN yang dikembangkan secara khusus untuk lingkungan dengan sumber daya komputasi terbatas, seperti perangkat mobile dan edge device (Gulzar, 2023). Dua komponen arsitektur utama yang membedakan MobileNetV2 dari arsitektur CNN konvensional adalah *inverted residual structure*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dan *linear bottleneck*. Pada struktur inverted residual, dimensi representasi fitur diperlebar di dalam blok komputasi, kemudian disempitkan kembali pada lapisan input dan output, berbeda dengan residual block konvensional yang melakukan penyempitan di dalam blok. Sementara itu, linear bottleneck mengacu pada desain lapisan terakhir pada setiap blok yang tidak menggunakan fungsi aktivasi nonlinear, dengan tujuan mencegah hilangnya informasi yang dapat terjadi akibat operasi nonlinearitas pada ruang berdimensi rendah (Duklan *et al.*, 2024).

(Gulzar, 2023) mendemonstrasikan penerapan MobileNetV2 sebagai *base model* dengan pendekatan *transfer learning* untuk klasifikasi citra buah, di mana lapisan klasifikasi asli diganti dengan *custom head* yang disesuaikan dengan jumlah kelas target. Melalui proses *fine-tuning* bertahap, model berhasil mencapai akurasi 99% pada *dataset* klasifikasi buah. Relevansi MobileNetV2 dalam penelitian ini terletak pada kemampuannya melakukan inferensi secara efisien pada server dengan spesifikasi perangkat keras terbatas (Intel Core i3-5005U), sehingga memungkinkan pemrosesan citra secara *real-time* dalam *pipeline* sistem *Smart lighting indoor*.

2.2.4 Transfer learning

Transfer learning merupakan pendekatan dalam *machine learning* yang memanfaatkan pengetahuan yang telah dipelajari sebuah model dari satu domain atau tugas tertentu untuk diaplikasikan pada domain atau tugas yang berbeda (Gulzar, 2023). Dua strategi *transfer learning* yang umum digunakan adalah: (1) *feature extraction*, di mana seluruh *layer* pretrained dibekukan dan hanya lapisan-lapisan baru yang ditambahkan yang dilatih; dan (2) *fine-tuning*, di mana *layer* pretrained di-*unfreeze* dan dilatih ulang menggunakan learning rate yang sangat kecil agar representasi fitur yang telah dipelajari dapat disesuaikan dengan domain target secara bertahap (Gulzar, 2023).

Bobot pretrained yang paling umum digunakan sebagai titik awal *transfer learning* adalah bobot hasil pelatihan pada *dataset* ImageNet. (Gulzar, 2023) menguraikan pendekatan hybrid dalam proses pelatihan, di mana pada tahap awal hanya lapisan baru yang dilatih, kemudian seluruh *layer* di-*unfreeze* setelah *epoch* ke-20 untuk



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dilanjutkan dengan *fine-tuning* bertahap. Pendekatan serupa juga dibuktikan efektif dalam konteks klasifikasi citra pada domain lokal, sebagaimana ditunjukkan oleh (Muhamad Malik Matin *et al.*, 2026) yang berhasil mencapai akurasi 96,52% menggunakan MobileNetV3Large dengan *transfer learning* pada *dataset* spesies burung Indonesia. Relevansi *transfer learning* dalam penelitian ini bersumber dari adanya kesenjangan domain (*domain gap*) antara bobot pretrained ImageNet dan karakteristik visual *dataset* aktivitas manusia *indoor*, yang menjadi justifikasi dilakukannya domain-specific *fine-tuning* menggunakan footage dari kamera Tapo C200 pada lingkungan pengujian aktual.

2.2.5 Histogram of Oriented Gradients (HOG)

Histogram of Oriented Gradients (HOG) merupakan deskriptor fitur yang merepresentasikan distribusi arah gradien intensitas piksel pada region-region lokal sebuah citra (Chen *et al.*, 2021). Metode ini pertama kali diperkenalkan oleh Dalal dan Triggs pada tahun 2005 dalam konteks deteksi manusia, sebagaimana dikutip dalam (Chen *et al.*, 2021).

Proses ekstraksi fitur HOG dilakukan melalui serangkaian tahapan sistematis. Pertama, citra dikonversi ke ruang warna grayscale. Selanjutnya, citra dibagi menjadi sejumlah blok menggunakan mekanisme sliding window, dan setiap blok dibagi lebih lanjut menjadi sel-sel (*cells*) berukuran lebih kecil. Pada setiap piksel, gradien horizontal dan vertikal dihitung menggunakan persamaan berikut (Chen *et al.*, 2021):

$$G_H(x, y) = I(x + 1, y) - I(x - 1, y)$$

$$G_V(x, y) = I(x, y + 1) - I(x, y - 1)$$

Berdasarkan kedua komponen gradien tersebut, arah gradien diperoleh melalui persamaan $d(x, y) = \arctan\left(\frac{G_H}{G_V}\right)$, sedangkan amplitudo gradien dihitung sebagai

$a(x, y) = \sqrt{G_H^2 + G_V^2}$. Nilai arah dan amplitudo selanjutnya digunakan untuk membentuk histogram orientasi pada setiap sel, yang kemudian dinormalisasi per blok dan dikoncatenasi menjadi vektor fitur final yang merepresentasikan keseluruhan citra (Chen *et al.*, 2021).



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Keunggulan deskriptor HOG terletak pada ketangguhannya terhadap variasi pencahayaan dan transformasi geometris minor. Akan tetapi, dalam penelitian ini ditemukan bahwa representasi fitur HOG tidak cukup diskriminatif untuk membedakan empat kelas aktivitas *indoor* yang digunakan, sebagaimana tercermin dari akurasi HOG+SVM yang hanya mencapai 69,28% pada data uji.

2.2.6 Local Binary Pattern

Local Binary Pattern (LBP) merupakan operator tekstur non-parametrik yang mendeskripsikan karakteristik fitur lokal sebuah citra berdasarkan perbandingan nilai piksel pusat dengan nilai piksel-piksel di sekitarnya dalam lingkungan tertentu (Chen *et al.*, 2021). Nilai LBP pada suatu piksel dihitung menggunakan persamaan berikut:

$$LBP_{P,R} = \sum_{i=0}^{P-1} s(x_i - x_c) 2^i$$

di mana $s(x) = 1$ jika $x \geq 0$, dan $s(x) = 0$ jika $x < 0$; x_c merupakan nilai piksel pusat; x_i adalah nilai piksel tetangga ke- i ; P adalah jumlah piksel tetangga yang dipertimbangkan; dan R adalah radius lingkungan di sekitar piksel pusat (Chen *et al.*, 2021).

Keunggulan LBP mencakup sifat invariannya terhadap perubahan rotasi dan skala keabuan, serta efisiensi komputasinya yang tinggi. Salah satu variasi yang umum digunakan adalah Centre-Symmetric LBP (CS-LBP), yang menggantikan perbandingan individual dengan perbandingan pasangan piksel simetris, sehingga dimensi representasi fitur berkurang dari $2^8 = 256$ menjadi $2^4 = 16$ (Chen *et al.*, 2021). Dalam penelitian ini, LBP digunakan sebagai salah satu komponen fitur pada pendekatan HOG+SVM, dikombinasikan dengan fitur HOG dan fitur tepi (*edge features*) untuk membentuk vektor fitur yang lebih komprehensif.

2.2.7 Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma supervised learning yang bekerja dengan menemukan hyperplane optimal yang memaksimalkan margin antara dua kelas dalam ruang fitur berdimensi tinggi (M. Khairul Anam *et al.*, 2025). Hyperplane tersebut ditentukan oleh data titik terdekat dari masing-masing kelas



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

yang disebut sebagai *support vectors*. Kemampuan SVM dalam menangani data yang tidak dapat dipisahkan secara linear diperluas melalui penggunaan fungsi *kernel* yang memetakan data ke ruang berdimensi lebih tinggi tanpa komputasi eksplisit.

Beberapa fungsi *kernel* yang umum digunakan dalam SVM antara lain: *kernel* Linear $K(x_i, x_j) = x_i \cdot x_j$, yang sesuai untuk data yang mendekati linear separable; *kernel* RBF (*Radial Basis Function*) $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$, yang efektif untuk pola nonlinear dengan parameter γ yang mengontrol radius pengaruh setiap titik data; *kernel* Polynomial $K(x_i, x_j) = (x_i \cdot x_j + c)^2$, yang mampu menangkap interaksi fitur orde tinggi; serta *kernel* Sigmoid $K(x_i, x_j) = \tanh(\alpha(x_i \cdot x_j) + C)$ (Anam *et al.*, 2025). Hyperparameter utama yang memengaruhi performa SVM meliputi C sebagai parameter regularisasi yang mengontrol trade-off antara lebar margin dan toleransi terhadap kesalahan klasifikasi, γ untuk *kernel* RBF, serta degree d untuk *kernel* Polynomial.

Kelemahan SVM mencakup beban komputasi yang berat pada *dataset* berskala besar, sensitivitas terhadap data noise dan outlier, serta penurunan akurasi yang signifikan apabila pemilihan *kernel* dan hyperparameter tidak sesuai dengan karakteristik data (M. Khairul Anam *et al.*, 2025). Dalam penelitian ini, SVM dengan *kernel* RBF ($C=20$, $\gamma=0,0001$) digunakan sebagai pengklasifikasi pada *pipeline* HOG+SVM. Hasil evaluasi menunjukkan akurasi 69,28% pada data uji dengan akurasi latih 100%, mengindikasikan terjadinya *severe overfitting* yang memperkuat kesimpulan bahwa keterbatasan sistem terletak pada kualitas representasi fitur, bukan pada pilihan pengklasifikasi.

2.2.8 Sistem Berbasis Aturan (*Rule-Based System*)

Sistem berbasis aturan (*rule-based system*) merupakan sistem yang menerapkan logika kondisional berbentuk aturan IF-THEN pada data masukan untuk menghasilkan keputusan atau aksi tertentu secara deterministik (Alnattah *et al.*, 2025). Komponen utama yang menyusun sistem ini adalah: (1) sekumpulan aturan (*rule sets*) yang mendefinisikan kondisi masukan dan aksi keluaran yang



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

bersesuaian; dan (2) *inference engine* yang bertugas memproses aturan-aturan tersebut terhadap data masukan yang diterima secara *real-time*.

Keunggulan sistem berbasis aturan terletak pada sifatnya yang transparan, mudah diinterpretasikan, deterministik, dan fleksibel terhadap pembaruan kondisi maupun aturan (Alnattah *et al.*, 2025). Penerapan logika IF-THEN berbasis data sensor pada mikrokontroler ESP32 telah dibuktikan mampu mengontrol aktuator secara otomatis dan responsif dalam konteks sistem otomasi, sebagaimana ditunjukkan oleh (Muhammad Zikri, Muhammad Fikry and Rizki Suwanda, 2025) pada implementasi smart greenhouse dengan *threshold* sensor LDR sebesar 3400.

Dalam penelitian ini, sistem berbasis aturan diimplementasikan sebagai mekanisme pengambilan keputusan kondisi lampu yang mempertimbangkan kombinasi dua masukan: hasil klasifikasi aktivitas dari model MobileNetV2 dan nilai tingkat kecerahan cahaya dari sensor LDR. Struktur aturan yang diterapkan adalah sebagai berikut: apabila kelas yang terdeteksi adalah *empty_room*, lampu dimatikan (OFF); apabila kelas yang terdeteksi adalah *lying_down* dan kondisi ruangan gelap, lampu diredupkan pada level 15% (DIM); apabila kelas yang terdeteksi adalah *sitting* atau *standing* dan kondisi ruangan gelap, lampu dinyalakan penuh (ON); serta apabila kondisi ruangan terdeteksi terang dalam kondisi aktivitas apapun, lampu dimatikan (OFF).

2.2.9 Grad-CAM (Gradient-weighted Class Activation Mapping)

Grad-CAM merupakan metode *Explainable Artificial Intelligence* (XAI) berbasis gradien yang digunakan untuk menghasilkan visualisasi berupa peta perhatian (*attention map*) yang menunjukkan region-region pada citra masukan yang paling berpengaruh terhadap prediksi sebuah model CNN (van Zyl, Ye and Naidoo, 2023). Grad-CAM termasuk dalam kategori XAI yang bersifat model-specific, sehingga penerapannya terbatas pada model yang mengandung lapisan konvolusi.

Prinsip kerja Grad-CAM memanfaatkan properti arsitektur CNN di mana hubungan spasial data dipertahankan setelah melalui lapisan-lapisan konvolusi. Perhitungan peta aktivasi dilakukan melalui dua tahap. Pertama, bobot kepentingan untuk filter ke-k pada kelas ke-j dihitung dengan persamaan (van Zyl, Ye and Naidoo, 2023):



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

$$w_j^k = \frac{1}{N} \sum_{i=0}^n \max \left(0, \frac{\partial y}{\partial A_{i,j}^k} \right)$$

di mana N adalah jumlah elemen dalam feature map, y adalah output model, dan $A_{\{i,j\}}^k$ adalah feature map ke- k dari *layer* konvolusi terakhir. Kedua, peta aktivasi akhir diperoleh melalui persamaan:

$$\Omega_j = \text{ReLU} \left(\sum_{K=1}^K w_j^K A_j^K \right)$$

Penerapan fungsi ReLU memastikan bahwa hanya kontribusi positif yang dipertahankan dalam peta aktivasi, sehingga visualisasi yang dihasilkan mencerminkan region yang secara aktif mendorong prediksi kelas tertentu (van Zyl, Ye and Naidoo, 2023). Keunggulan Grad-CAM terletak pada efisiensi komputasinya, karena hanya memerlukan satu forward pass dan satu partial backpropagation untuk menghasilkan peta aktivasi.

Dalam penelitian ini, Grad-CAM digunakan untuk memverifikasi bahwa model NB3 (MobileNetV2 Finetune Full) memfokuskan perhatiannya pada region tubuh manusia yang relevan secara semantik, bukan pada artefak latar belakang atau pola yang tidak bermakna, sehingga memberikan justifikasi interpretabilitas terhadap keputusan prediksi model.

2.2.10 Metrik Evaluasi

Evaluasi performa model klasifikasi dalam penelitian ini dilakukan menggunakan empat metrik utama yang bersumber dari *confusion matrix*, yaitu matriks yang merangkum distribusi hasil prediksi model ke dalam kategori True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) (Gulzar, 2023).

Akurasi (*accuracy*) mengukur proporsi seluruh prediksi yang benar terhadap total data, diformulasikan sebagai $\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$. Presisi (*precision*) mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif, diformulasikan sebagai $\text{Precision} = TP / (TP + FP)$. *Recall* mengukur proporsi data positif yang berhasil terdeteksi terhadap seluruh data yang sebenarnya positif, diformulasikan sebagai $\text{Recall} = TP / (TP + FN)$. *F1-score* merupakan rata-rata harmonik antara presisi dan *recall*, diformulasikan sebagai $\text{F1-score} = 2 \times$



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

$(Precision \times Recall) / (Precision + Recall)$, dan menjadi metrik yang sangat relevan pada kondisi distribusi kelas yang tidak seimbang (M. Khairul Anam *et al.*, 2025).

Dalam penelitian ini, keempat metrik tersebut digunakan secara bersama-sama untuk mengevaluasi dan membandingkan performa model MobileNetV2 dan model HOG+SVM, serta untuk menganalisis distribusi hasil klasifikasi pada setiap kelas aktivitas melalui *confusion matrix*.

Selain keempat metrik tersebut, tingkat kesepakatan antara hasil prediksi model dan label sebenarnya diukur menggunakan koefisien *Cohen's Kappa* (κ) yang memperhitungkan kemungkinan kesepakatan terjadi secara kebetulan, dihitung dengan persamaan $\kappa = (p_o - p_e) / (1 - p_e)$, dengan p_o merupakan proporsi kesepakatan teramati dan p_e merupakan proporsi kesepakatan yang diharapkan terjadi secara kebetulan berdasarkan distribusi marginal kelas. Untuk interpretasi kekuatan kesepakatan, penelitian ini mengacu pada kategorisasi yang diusulkan oleh (Landis and Koch, 1977), yaitu nilai 0,61–0,80 dikategorikan *substantial* dan 0,81–1,00 dikategorikan *almost perfect*. (Landis and Koch, 1977) sendiri menyatakan bahwa pembagian kategori tersebut bersifat arbitrer, namun tetap berguna sebagai *benchmark* praktis dalam interpretasi nilai *Kappa*.

POLITEKNIK
NEGERI
JAKARTA



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB III METODE PENELITIAN

3.1 Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian rekayasa sistem (*system development*) yang bersifat eksperimental komparatif. Pendekatan ini dipilih karena penelitian berfokus pada pengembangan sistem *Smart lighting indoor* yang mengintegrasikan klasifikasi aktivitas manusia berbasis *computer vision* dan deteksi tingkat kecerahan cahaya ruangan menggunakan sensor cahaya (LDR), sekaligus melakukan perbandingan terukur antara dua pendekatan klasifikasi aktivitas, yaitu *machine learning* berbasis HOG+SVM dan *deep learning* berbasis MobileNetV2, untuk menentukan metode yang paling optimal digunakan dalam sistem.

Teknik pengumpulan data pada penelitian ini dilakukan melalui dua cara. Pertama, konstruksi *dataset* secara mandiri dengan merekam citra kondisi ruangan pada empat kelas aktivitas, yaitu *empty_room*, *lying_down*, *sitting*, dan *standing*, menggunakan kamera yang dipasang di lingkungan *indoor* kamar tidur. Kedua, pengumpulan data hasil observasi sistem selama proses pengujian, yang mencakup pencatatan respons sistem terhadap setiap skenario kondisi ruangan beserta keputusan kondisi lampu yang dihasilkan.

Teknik analisis data pada penelitian ini mencakup dua aspek utama. Pertama, analisis evaluasi komparatif performa model klasifikasi aktivitas menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, serta *confusion matrix* untuk menganalisis distribusi hasil klasifikasi pada setiap kelas aktivitas. Kedua, analisis kinerja sistem *Smart lighting indoor* secara keseluruhan dengan membandingkan keputusan kondisi lampu yang dihasilkan sistem terhadap kondisi aktual ruangan pada setiap skenario pengujian.


3.2 Tahapan Penelitian

Penelitian ini diselesaikan melalui serangkaian tahapan yang dilakukan secara sistematis. Tahapan penelitian secara keseluruhan digambarkan pada Gambar 3.1.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 3.1 Diagram Alur Rancangan Penelitian

Penjelasan setiap tahapan penelitian adalah sebagai berikut:

1. Identifikasi Masalah

Tahap identifikasi masalah dilakukan untuk mengkaji permasalahan yang terjadi pada sistem pencahayaan kamar tidur yang masih bersifat manual atau belum adaptif terhadap kondisi penggunaan ruangan secara aktual. Identifikasi dilakukan melalui kajian literatur dan wawancara terhadap pengguna kamar tidur untuk mengetahui kondisi penggunaan lampu yang belum menyesuaikan dengan keberadaan dan aktivitas spesifik penghuni serta belum mempertimbangkan tingkat kecerahan cahaya ruangan secara terintegrasi.

2. Studi Literatur

Tahap studi literatur dilakukan dengan mengkaji jurnal nasional dan internasional yang relevan dengan topik penelitian. Kajian mencakup konsep



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Smart lighting indoor, computer vision, klasifikasi aktivitas manusia berbasis kamera, pendekatan *machine learning* menggunakan HOG dan SVM, pendekatan *deep learning* menggunakan arsitektur MobileNetV2 dan mekanisme *transfer learning*, serta sistem pengambilan keputusan berbasis aturan (*rule-based decision*). Hasil studi literatur digunakan sebagai landasan teoritis dalam perancangan dan implementasi sistem.

3. Konstruksi *Dataset*

Tahap konstruksi *dataset* dilakukan untuk membangun data latih dan data uji yang digunakan dalam pelatihan dan evaluasi model klasifikasi aktivitas manusia. *Dataset* yang digunakan merupakan hasil kurasi dari Video *Dataset* for Human Action Recognition yang bersumber dari Kaggle, dengan penambahan kelas *empty_room* secara mandiri dan data domain-specific menggunakan kamera Tapo C200. *Dataset* hasil modifikasi ini selanjutnya disebut sebagai *dataset HAR Indoor* (kurasi), dengan total sekitar 3.610 citra yang terdistribusi pada keempat kelas, dengan rasio pembagian data latih dan data uji sebesar 80:20.

4. Implementasi dan Evaluasi Komparatif Model Klasifikasi Aktivitas

Tahap ini mencakup implementasi dua pendekatan klasifikasi aktivitas manusia secara komparatif menggunakan *dataset* yang telah dikonstruksi. Pendekatan pertama adalah *machine learning* menggunakan ekstraksi fitur Histogram of Oriented Gradients (HOG) yang dikombinasikan dengan classifier Support Vector Machine (SVM). Fitur HOG diekstraksi dari citra untuk merepresentasikan distribusi gradien intensitas pada area lokal citra, kemudian digunakan sebagai masukan pada classifier SVM untuk mengklasifikasikan aktivitas manusia ke dalam salah satu dari empat kelas yang telah ditentukan. Pendekatan kedua adalah *deep learning* menggunakan arsitektur MobileNetV2 dengan mekanisme *transfer learning* berbasis bobot pretrained ImageNet. Model dilatih menggunakan *dataset HAR Indoor* (kurasi) dengan rasio pembagian data 80:20.

Evaluasi performa kedua pendekatan dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, serta *confusion matrix* untuk menganalisis



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

distribusi hasil klasifikasi pada setiap kelas aktivitas. Berdasarkan hasil evaluasi, model MobileNetV2 dipilih sebagai model final karena menghasilkan akurasi sebesar 95,21% pada data uji, jauh melampaui performa pendekatan HOG+SVM yang menghasilkan akurasi sekitar 69%.

5. Perancangan Sistem *Smart lighting indoor*


Tahap perancangan sistem dilakukan untuk menyusun arsitektur dan alur kerja sistem *Smart lighting indoor* secara keseluruhan. Sistem dirancang dengan *pipeline* sebagai berikut: akuisisi citra oleh kamera → klasifikasi aktivitas manusia menggunakan model MobileNetV2 → pengambilan keputusan kondisi lampu melalui mekanisme *rule-based decision* yang mempertimbangkan hasil klasifikasi aktivitas dan data tingkat kecerahan cahaya dari sensor LDR → eksekusi kondisi lampu melalui mikrokontroler ESP32. Mekanisme pengambilan keputusan dirancang dalam bentuk aturan IF-THEN yang menentukan kondisi lampu secara otomatis sesuai dengan kombinasi hasil klasifikasi aktivitas dan tingkat kecerahan cahaya ruangan. Arsitektur *pipeline* sistem yang menjadi acuan pada tahap implementasi ditunjukkan pada Gambar 3.2.

POLITEKNIK
NEGERI
JAKARTA



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 3.2 Arsitektur Pipeline Sistem Smart lighting indoor

6. Implementasi Sistem

Tahap implementasi sistem mencakup penerapan seluruh komponen sistem *Smart lighting indoor* secara terintegrasi. Model MobileNetV2 yang telah dilatih diimplementasikan sebagai komponen klasifikasi aktivitas pada *pipeline* sistem. Selain itu, diimplementasikan pula modul pembacaan tingkat kecerahan cahaya ruangan menggunakan sensor LDR, mekanisme pengambilan keputusan berbasis aturan, serta integrasi keseluruhan sistem dengan mikrokontroler ESP32 untuk pengendalian lampu secara otomatis.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

7. Pengujian dan Analisis Sistem

Tahap pengujian sistem dilakukan untuk memastikan seluruh fungsi sistem berjalan sesuai dengan rancangan. Pengujian dilakukan pada beberapa skenario kondisi ruangan, yaitu kondisi kamar tidur kosong (*empty_room*), kondisi penghuni dalam posisi berbaring (*lying_down*), kondisi penghuni dalam posisi duduk (*sitting*), dan kondisi penghuni dalam posisi berdiri (*standing*), dengan variasi tingkat kecerahan cahaya ruangan pada masing-masing skenario. Hasil pengujian dianalisis dengan membandingkan keputusan kondisi lampu yang dihasilkan sistem terhadap kondisi aktual ruangan untuk menilai kesesuaian dan konsistensi sistem secara keseluruhan.

3.3 Objek Penelitian

Objek penelitian pada penelitian ini adalah sistem *Smart lighting indoor* berbasis *computer vision* yang dirancang untuk mengendalikan pencahayaan kamar tidur secara otomatis dan adaptif. Sistem memanfaatkan kamera sebagai sensor utama untuk mengklasifikasikan aktivitas spesifik manusia di dalam ruangan, serta sensor cahaya (LDR) sebagai modul terpisah untuk mendeteksi tingkat kecerahan cahaya ruangan. Kedua informasi tersebut diproses menggunakan mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*) untuk menentukan kondisi lampu secara otomatis melalui mikrokontroler ESP32.

Komponen utama yang menjadi objek penelitian meliputi:

1. *Dataset* aktivitas manusia HAR *Indoor* (kurasi) yang dikurasi dari Video *Dataset* for Human Action Recognition (Kaggle), terdiri dari sekitar 3.610 citra dengan empat kelas aktivitas, yaitu *empty_room*, *lying_down*, *sitting*, dan *standing*, dengan rasio pembagian data latih dan data uji sebesar 80:20.
2. Model klasifikasi aktivitas yang dikembangkan melalui evaluasi komparatif antara pendekatan *machine learning* berbasis HOG+SVM dan pendekatan *deep learning* berbasis MobileNetV2, dengan model MobileNetV2 sebagai model final yang diimplementasikan dalam sistem berdasarkan hasil evaluasi.
3. Mekanisme pengambilan keputusan berbasis aturan (*rule-based decision*) yang memproses hasil klasifikasi aktivitas manusia dan data tingkat kecerahan

cahaya ruangan dari sensor LDR untuk menentukan kondisi lampu secara otomatis.

4. Integrasi sistem yang mencakup komunikasi antara laptop sebagai server pemrosesan utama dengan mikrokontroler ESP32 sebagai pengendali lampu, yang diuji pada skenario kamar tidur sebagai ruang uji penelitian.



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB IV

HASIL DAN PEMBAHASAN

4.1 Analisis Kebutuhan

Tahap analisis kebutuhan dilakukan untuk mengidentifikasi dan mendefinisikan seluruh kebutuhan sistem *Smart lighting indoor* berbasis *computer vision* sebelum tahap perancangan dan implementasi dilaksanakan. Analisis ini mencakup kebutuhan fungsional, kebutuhan non-fungsional, serta spesifikasi perangkat keras dan perangkat lunak yang digunakan dalam pengembangan sistem.

4.1.1 Kebutuhan Fungsional

Kebutuhan fungsional mendefinisikan fungsi-fungsi yang harus dapat dilaksanakan oleh sistem. Berdasarkan rumusan masalah dan tujuan penelitian yang telah ditetapkan, kebutuhan fungsional sistem *Smart lighting indoor* diidentifikasi sebagai berikut.

Tabel 2 Kebutuhan Fungsional Sistem

No	Kode	Deskripsi Kebutuhan	Komponen
1	KF-01	Sistem dapat mengakuisisi frame video secara <i>real-time</i> dari kamera Tapo C200 melalui protokol RTSP	Kamera, Server
2	KF-02	Sistem dapat mengklasifikasikan aktivitas manusia ke dalam empat kelas: <i>empty_room</i> , <i>lying_down</i> , <i>sitting</i> , dan <i>standing</i> menggunakan model MobileNetV2	Server, Model CV
3	KF-03	Sistem dapat membaca nilai tingkat kecerahan cahaya ruangan menggunakan sensor LDR yang terhubung ke mikrokontroler ESP32	ESP32, Sensor LDR
4	KF-04	Sistem dapat mengambil keputusan kondisi lampu (ON, OFF, DIM 15%) secara otomatis berdasarkan kombinasi hasil klasifikasi aktivitas dan nilai sensor LDR melalui mekanisme <i>rule-based decision</i>	ESP32
5	KF-05	Sistem dapat mengendalikan aktuator lampu (relay ON/OFF dan AC dimmer RobotDyn) sesuai dengan keputusan <i>rule-based</i> yang dihasilkan	ESP32, Relay, Dimmer
6	KF-06	Sistem dapat melakukan polling prediksi aktivitas secara berkala setiap 10 detik melalui komunikasi HTTP antara ESP32 dan server <i>inference</i>	ESP32, Server

Tabel 2 menjelaskan sistem *Smart lighting indoor* yang dikembangkan memiliki enam kebutuhan fungsional utama yang mencakup keseluruhan alur kerja sistem



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dari akuisisi citra hingga pengendalian aktuator lampu. Keenam kebutuhan tersebut mencerminkan arsitektur *pipeline* sistem yang terdiri dari komponen kamera, server *inference*, mikrokontroler ESP32, sensor LDR, dan aktuator lampu.

4.1.2 Kebutuhan Non-Fungsional

Kebutuhan non-fungsional mendefinisikan batasan dan parameter kualitas yang harus dipenuhi oleh sistem di luar fungsi utamanya. Kebutuhan non-fungsional sistem *Smart lighting indoor* diidentifikasi sebagai berikut.

Tabel 3 Kebutuhan Non-Fungsional Sistem

No	Kode	Deskripsi Kebutuhan	Parameter
1	KNF-01	Akurasi model klasifikasi aktivitas manusia memenuhi target minimum yang ditetapkan	Akurasi $\geq 85\%$ pada data uji
2	KNF-02	Sistem melakukan siklus pembacaan dan pengambilan keputusan secara berkala dengan interval yang konsisten	Interval polling 10 detik
3	KNF-03	Sistem dapat berjalan secara stabil dan terus-menerus tanpa memerlukan koneksi internet eksternal	Jaringan lokal/hotspot, tanpa ketergantungan internet

Tabel 3 menjelaskan kebutuhan non-fungsional yang paling kritis dalam penelitian ini adalah KNF-01, yaitu akurasi model klasifikasi aktivitas manusia yang harus mencapai minimum 85% pada data uji. Nilai ambang tersebut ditetapkan dengan mengacu pada rentang kinerja yang dilaporkan pada penelitian pengenalan aktivitas manusia berbasis citra. (Kolawole, Irhebhude and Odion, 2025) melaporkan akurasi klasifikasi aksi manusia multikelas sebesar 63,8% hingga 86,4%, dengan capaian tertinggi diperoleh melalui kombinasi fitur HOG dan *region descriptor* yang dinilai menunjukkan kinerja efektif. Pada kondisi ruangan nyata, deteksi kehadiran manusia berbasis HOG dilaporkan hanya mencapai akurasi terbaik sebesar 66% (Anggono *et al.*, 2025), sejalan dengan hasil baseline HOG+SVM pada penelitian ini yang memperoleh akurasi 69,28%. Berdasarkan rentang tersebut, ambang 85% ditetapkan agar model klasifikasi yang digunakan dalam sistem setidaknya menyamai capaian terbaik pendekatan fitur handcrafted yang dilaporkan dalam literatur, sehingga penggunaan pendekatan *deep learning* yang lebih kompleks memiliki justifikasi kinerja yang memadai. Model dengan akurasi di bawah ambang tersebut dinilai belum layak digunakan sebagai dasar pengambilan keputusan pada



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

sistem *Smart lighting indoor*. KNF-02 dan KNF-03 berkaitan dengan aspek operasional sistem yang memastikan sistem dapat berjalan secara konsisten dan mandiri tanpa ketergantungan pada infrastruktur jaringan eksternal.

4.1.3 Spesifikasi Perangkat

Pengembangan sistem *Smart lighting indoor* melibatkan dua lingkungan komputasi yang berbeda: lingkungan pelatihan model yang menggunakan laptop dengan GPU dedicated, dan lingkungan deployment yang menggunakan server *inference* terpisah. Pemisahan ini dilakukan karena proses pelatihan model membutuhkan akselerasi GPU yang tidak tersedia pada server *inference*, sementara server *inference* membutuhkan kemampuan berjalan secara kontinu sebagai layanan. Spesifikasi seluruh perangkat yang digunakan dirangkum dalam Tabel 4.

Tabel 4 Spesifikasi Perangkat

Komponen	Spesifikasi	Fungsi Dalam Sistem
Laptop (<i>Training</i>)	Windows 11, GPU NVIDIA GTX 1650 Mobile (4GB VRAM), Python 3.10, PyTorch 2.10 + CUDA 12.8	Pelatihan dan evaluasi model MobileNetV2 dan SVM
Ubuntu Server (<i>Inference</i>)	Ubuntu Server, Intel Core i3-5005U, RAM 15GB, FastAPI	Menjalankan <i>inference</i> model MobileNetV2 secara <i>real-time</i> dari stream RTSP kamera
Kamera Tapo C200	Kamera IP, resolusi 1080p, protokol RTSP, dipasang di dinding kamar	Akuisisi frame video dari ruangan untuk dikirim ke server <i>inference</i>
Arduino ESP32	Mikrokontroler ESP32, pin ADC GPIO 32 untuk LDR, koneksi WiFi	Polling prediksi ke server, pembacaan LDR, eksekusi <i>rule-based decision</i> , kontrol aktuator
Sensor LDR	Light Dependent Resistor, terhubung ke pin ADC ESP32 (GPIO 32), <i>threshold</i> nilai inverted > 2500 = terang	Mendeteksi tingkat kecerahan cahaya ruangan sebagai input <i>rule-based decision</i>
Relay 1 Channel	Relay generic 1 channel	Mengontrol kondisi ON/OFF lampu
Lampu <i>Real-time</i> Bulb	60W, 0.26 A, 220V/50-60 Hz, E27 Socket, CCT Warm White 2900K	Aktuator akhir sistem; sumber cahaya yang dikendalikan oleh relay dan AC dimmer sesuai keputusan <i>rule-based</i>
AC Dimmer RobotDyn	AC Dimmer RobotDyn, kurva logaritmik, setting 15% brightness	Mengontrol intensitas cahaya lampu pada kondisi DIM saat aktivitas <i>lying down</i> terdeteksi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pemisahan fungsi antara laptop (*training*) dan Ubuntu server (*inference*) merupakan keputusan arsitektur yang didasarkan pada keterbatasan sumber daya. Proses pelatihan model MobileNetV2 membutuhkan VRAM yang memadai untuk memproses *batch* gambar berukuran 224×224 piksel, sehingga dilakukan pada laptop dengan GPU NVIDIA GTX 1650 Mobile. Sementara itu, *inference* model pada kondisi deployment hanya membutuhkan CPU karena pemrosesan dilakukan per frame dengan interval 10 detik, sehingga Ubuntu server dengan prosesor Intel Core i3-5005U dinilai memadai untuk kebutuhan tersebut.

4.2 Perancangan Sistem

Perancangan sistem *Smart lighting indoor* mencakup empat aspek utama: arsitektur *pipeline* sistem secara keseluruhan, topologi jaringan antar komponen, perancangan *rule-based decision*, dan konfigurasi perangkat keras. Seluruh komponen dirancang untuk bekerja secara terintegrasi dalam satu siklus otomatis yang berjalan setiap 10 detik.

4.2.1 Arsitektur Pipeline Sistem

Sistem *Smart lighting indoor* dirancang menggunakan arsitektur *pipeline hybrid* yang memisahkan tugas deteksi aktivitas (*computer vision*) dari tugas pengambilan keputusan (*rule-based*). Pemisahan ini mengikuti rekomendasi dosen pembimbing untuk meningkatkan modularitas dan interpretabilitas sistem setiap komponen memiliki tanggung jawab yang terdefinisi dengan jelas dan dapat diuji secara independen.

Pipeline sistem terdiri dari lima tahap yang berjalan secara siklikal:

- A. Akuisisi Frame: Kamera Tapo C200 yang terpasang di dinding kamar mengirimkan stream video melalui protokol RTSP (`rtsp://192.168.100.15:554/stream2`). Server *inference* melakukan capture satu frame dari stream tersebut.
- B. Preprocessing Frame: Frame yang diterima dirotasi dan di-resize ke ukuran 224×224 piksel sesuai kebutuhan arsitektur MobileNetV2.
- C. Inferensi Model: Model MobileNetV2 NB3 (Finetune Full) mengklasifikasikan frame ke salah satu dari empat kelas aktivitas: `empty_room`, `lying_down`, `sitting`, atau `standing`.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- D. Pengiriman Prediksi: Hasil prediksi dikirimkan ke ESP32 sebagai respons JSON melalui endpoint HTTP GET /stream-predict setiap 10 detik.
- E. *Rule-based Decision* & Aktuasi: ESP32 mengkombinasikan prediksi aktivitas dari server dengan nilai sensor LDR untuk menentukan keputusan lampu (ON, OFF, atau DIM 15%), kemudian mengeksekusi keputusan tersebut melalui relay dan AC dimmer.

Kelima tahap tersebut membentuk siklus tertutup yang direpresentasikan pada Gambar 4.1.



Gambar 4.1 Arsitektur *Pipeline* Sistem

4.2.2 Topologi Jaringan




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Sistem dirancang untuk beroperasi dalam jaringan lokal tanpa ketergantungan pada koneksi internet eksternal. Seluruh komunikasi antar komponen berlangsung dalam satu jaringan WiFi yang sama, menjamin latensi rendah dan keandalan koneksi yang tidak terpengaruh oleh kondisi internet.

Komponen server *inference* (Ubuntu Server) dan mikrokontroler ESP32 terhubung ke jaringan WiFi lokal menggunakan router rumah. Arsitektur jaringan ini juga memungkinkan penggantian router dengan mobile hotspot dari ponsel tanpa perubahan konfigurasi pada kode sistem, selama kedua perangkat berada dalam jaringan yang sama, sebagaimana diilustrasikan pada Gambar 4.2.



Gambar 4.2 Topologi Jaringan Sistem

Konfigurasi kedua lingkungan komputasi yang digunakan server *inference* dan laptop *training* dirangkum pada Tabel 5.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 5 Konfigurasi Server dan Perangkat Komputasi

Parameter	Server <i>Inference</i> (Ubuntu)	Laptop <i>Training</i> (Windows 11)
Fungsi	<i>Inference real-time</i> MobileNetV2	Pelatihan dan evaluasi model
Prosesor	Intel Core i3-5005U	Ryzen 5 5600H
RAM	16 GB	32 GB
GPU	Intel HD Graphics 5500	NVIDIA GTX 1650 Mobile (4 GB VRAM)
Framework	FastAPI + PyTorch (CPU <i>inference</i>)	PyTorch 2.10 + CUDA 12.8
Endpoint	GET /stream-predict (JSON response)	-
Jaringan	WiFi Lokal (dapat juga via mobile hotspot)	-

4.2.3 Perancangan *Rule-based Decision*

Rule-based decision merupakan komponen pengambil keputusan yang diimplementasikan di dalam firmware Arduino ESP32. Komponen ini menerima dua input secara bersamaan: (1) hasil prediksi kelas aktivitas dari model *computer vision* yang dikirimkan oleh server *inference*, dan (2) nilai sensor LDR yang dibaca langsung oleh ESP32 dari pin ADC GPIO 32.

Perancangan *rule-based* mengikuti prinsip yang ditetapkan oleh dosen pembimbing, yaitu memisahkan lapisan deteksi aktivitas (model CV) dari lapisan pengambilan keputusan (*rule-based*). Dengan pemisahan ini, logika kontrol lampu dapat dimodifikasi secara independen tanpa mengubah model *deep learning*, dan sebaliknya.

Sensor LDR dikonfigurasi menggunakan nilai inverted dari ADC nilai lebih tinggi mengindikasikan kondisi lebih gelap, sebaliknya nilai lebih rendah mengindikasikan kondisi lebih terang. *Threshold* yang ditetapkan berdasarkan kalibrasi empiris adalah nilai > 2500 untuk kondisi terang dan nilai ≤ 2500 untuk kondisi gelap atau redup.

Aturan keputusan lengkap dirangkum dalam Tabel 6 berikut.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 6 *Rule-based Decision*

Aktivitas (Model CV)	Kondisi LDR	Nilai LDR (Inverted)	Keputusan Lampu
empty_room	Terang / Gelap	Semua nilai	OFF
sitting	Terang	> 2500	OFF
sitting	Gelap / Redup	≤ 2500	ON
standing	Terang	> 2500	OFF
standing	Gelap / Redup	≤ 2500	ON
lying_down	Terang / Gelap	Semua nilai	DIM 15%

Dari enam aturan yang dirancang, terdapat tiga pola keputusan yang dapat diamati. Pertama, kelas *empty_room* selalu menghasilkan keputusan OFF tanpa mempertimbangkan kondisi cahaya, karena ruangan kosong tidak memerlukan pencahayaan dalam kondisi apapun. Kedua, kelas *sitting* dan *standing* menghasilkan keputusan yang bergantung pada kondisi LDR OFF jika cahaya alami sudah cukup (terang), dan ON jika ruangan gelap atau redup. Ketiga, kelas *lying_down* selalu menghasilkan keputusan DIM 15% tanpa mempertimbangkan kondisi LDR, karena pengguna yang berbaring diasumsikan sedang beristirahat atau tidur sehingga pencahayaan redup lebih sesuai.




Gambar 4.3 Diagram Pohon Keputusan *Rule-based*

Struktur pengambilan keputusan *rule-based* digambarkan dalam bentuk diagram pohon pada Gambar 4.3, yang menunjukkan bagaimana hasil klasifikasi aktivitas dan nilai sensor LDR secara bersama-sama menentukan keputusan kondisi lampu, sementara alur eksekusinya secara rinci digambarkan pada *flowchart* Gambar 4.4.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.4 Flowchart Rule-based Decision

4.2.4 Konfigurasi Perangkat Keras ESP32

Arduino ESP32 berfungsi sebagai pusat kendali sistem yang mengintegrasikan komunikasi jaringan, pembacaan sensor, pengambilan keputusan, dan eksekusi aktuator dalam satu perangkat. Konfigurasi pin dan fungsi masing-masing komponen yang terhubung ke ESP32 dirangkum dalam Tabel 7.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 7 Konfigurasi Pin ESP32

Komponen	Pin / Konfigurasi	Fungsi
Sensor LDR	GPIO 32 (ADC)	Membaca nilai kecerahan cahaya ruangan; <i>threshold inverted</i> > 2500 = terang
Relay 1 Channel	GPIO 26	Kontrol ON/OFF lampu; LOW = relay aktif (lampu ON)
AC Dimmer RobotDyn	GPIO 4 (ZC), GPIO 5 (PSM)	Kontrol intensitas cahaya; setting 15% brightness untuk kondisi lying down
WiFi	Station Mode	Koneksi ke jaringan lokal untuk polling HTTP ke server <i>inference</i>
Polling Interval	10 Detik	Interval permintaan prediksi aktivitas ke endpoint /stream-predict

Penggunaan AC Dimmer RobotDyn membutuhkan dua pin: pin Zero-Crossing (ZC) untuk mendeteksi titik nol gelombang AC dan pin PSM (Phase-Shift Modulation) untuk mengontrol sudut penyalan triac. Dimmer dikonfigurasi dengan kurva logaritmik untuk menghasilkan penurunan kecerahan yang terasa natural secara perseptual, dengan nilai setting 15% yang menghasilkan intensitas cahaya redup yang sesuai untuk kondisi istirahat atau tidur.



Gambar 4.5 Skema Rangkaian Perangkat Keras ESP32



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4.5 menunjukkan skema rangkaian perangkat keras sistem *Smart lighting indoor* yang terdiri dari empat komponen utama yang terhubung ke mikrokontroler ESP32. Sensor LDR terhubung ke pin GPIO 32 yang berfungsi sebagai input ADC untuk membaca nilai kecerahan cahaya ruangan. Modul relay 1 channel terhubung ke pin GPIO 26 sebagai aktuator kontrol ON/OFF lampu dengan konfigurasi active LOW. AC Dimmer RobotDyn terhubung ke dua pin sekaligus GPIO 4 untuk sinyal zero-crossing detection dan GPIO 5 untuk sinyal phase-shift modulation yang bersama-sama mengontrol intensitas cahaya lampu pada kondisi DIM 15%. Seluruh komponen berbagi jalur ground (GND) yang sama dengan ESP32, sementara modul relay mendapat sumber tegangan 5V dari pin VIN ESP32 karena relay membutuhkan tegangan operasi 5V yang tidak dapat dipenuhi oleh pin 3.3V.

4.3 Implementasi Sistem

Tahap implementasi mencakup seluruh proses pengembangan sistem mulai dari konstruksi *dataset*, eksperimen dan pemilihan model, hingga integrasi komponen IoT. Sub-bab ini juga memuat analisis eksplainabilitas model menggunakan Grad-CAM sebagai bagian dari evaluasi kualitatif hasil implementasi.

4.3.1 Konstruksi *Dataset*

Dataset yang digunakan dalam penelitian ini merupakan hasil kurasi dari Video *Dataset* for Human Action Recognition yang bersumber dari Kaggle. *Dataset* asli berformat video AVI dengan tujuh kelas aktivitas: sitting, sit down, standing, stand up, walking, lying down, dan fall down. Untuk menyesuaikan dengan kebutuhan sistem *Smart lighting indoor*, dilakukan serangkaian modifikasi sebagai berikut: (1) kelas sit down dan stand up dihapus karena merupakan aktivitas transisi yang tidak merepresentasikan kondisi statis pengguna; (2) kelas fall down dihapus karena berada di luar skenario penggunaan sistem; (3) kelas walking dihapus karena secara visual ambigu dengan kelas standing dari sudut pandang kamera atas; dan (4) kelas empty_room ditambahkan secara manual menggunakan gambar statis ruangan tanpa penghuni. *Dataset* hasil modifikasi ini selanjutnya disebut sebagai *dataset HAR Indoor* (kurasi).



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Penghapusan kelas walking terbukti memberikan dampak signifikan terhadap akurasi model sebelum penghapusan (V5b, 5 kelas) akurasi mencapai 80.36%, sedangkan setelah penghapusan (V5c, 4 kelas) akurasi meningkat menjadi 95.21% (+14.85%). Hal ini mengkonfirmasi bahwa reduksi ambiguitas kelas lebih berdampak dibanding perubahan arsitektur model dalam konteks *dataset* ini.

Setiap frame diekstrak dari video menggunakan strategi 8-zona sampling merata (5%–90% dari durasi video) untuk memastikan representasi temporal yang beragam dari setiap aktivitas. Frame kemudian di-resize ke ukuran 224×224 piksel sesuai kebutuhan arsitektur MobileNetV2. Distribusi *dataset* final dirangkum dalam Tabel 8.

Tabel 8 Distribusi *Dataset HAR Indoor* (Kurasi)

Kelas	<i>Train</i>	Test	Total	Rasio <i>Train:Test</i>	Sumber
empty_room	608	152	760	80:20	Kaggle + Custom
lying_down	750	200	950	79:21	Kaggle
sitting	750	200	950	79:21	Kaggle
standing	750	200	950	79:21	Kaggle
TOTAL	2858	752	3610	~79:21	-

Kelas empty_room memiliki jumlah gambar lebih sedikit dibanding kelas lainnya (760 vs 950) karena sumber datanya berbeda kelas ini menggunakan gambar statis dari *dataset* V4 (Class_0_Tidak_Ada_Orang), bukan video HAR. Meskipun terdapat ketidakseimbangan minor, kelas empty_room justru mencapai akurasi 100% pada seluruh eksperimen, mengindikasikan bahwa fitur visual ruangan kosong cukup distinktif sehingga jumlah data yang lebih kecil tidak menjadi hambatan.

4.3.2 Perbandingan Pendekatan *Machine learning* dan *Deep learning*

Sebelum menentukan pendekatan yang digunakan dalam sistem, dilakukan eksperimen komparatif antara *Machine learning* klasik (SVM dengan fitur HOG+Edge+LBP) dan *Deep learning* (MobileNetV2 dengan *transfer learning*). Eksperimen ini menggunakan *dataset* HAR *Indoor* (kurasi) yang sama, dengan masing-masing pendekatan diuji pada dua kondisi: dengan pre-processing dan tanpa pre-processing.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Untuk SVM, pre-processing yang diuji adalah normalisasi fitur menggunakan StandardScaler. Untuk MobileNetV2, pre-processing yang diuji mencakup augmentasi data (RandomHorizontalFlip, ColorJitter, RandomRotation, RandomGrayscale) dan normalisasi ImageNet. Resize gambar dan ekstraksi fitur dasar dipertahankan pada semua kondisi karena merupakan kebutuhan teknis yang tidak dapat dihilangkan.

Tabel 9 Perbandingan Keseluruhan SVM vs MobileNetV2

Metrik	SVM+PP	SVM NoPP	DL+PP	DL NoPP
Test Accuracy	69.28%	67.02%	95.21%	96.14%
Train Accuracy	100.00%	100.00%	99.13%	99.20%
Train-test gap	30.72%	32.98%	3.91%	3.05%
Best CV Score	66.73%	63.51%	N/A	N/A
Target $\geq 85\%$	Tidak Tercapai	Tidak Tercapai	Tercapai	Tercapai

Tabel 9 menjelaskan perbedaan performa antara SVM dan MobileNetV2 mencapai ~26–29%, jauh melampaui dampak pre-processing pada masing-masing pendekatan yang hanya berkisar $\pm 2\%$. Hal ini menegaskan bahwa pemilihan metode merupakan faktor penentu yang jauh lebih krusial dibanding konfigurasi pre-processing.

Tabel 10 Classification Report per Kelas SVM

Kelas	Precision	Recall	F1	Precision	Recall	F1	Delta Recall
	(Dengan PP)	(Dengan PP)	(Dengan PP)	(Tanpa PP)	(Tanpa PP)	(Tanpa PP)	
empty room	0.95	1.00	0.97	0.93	1.00	0.96	0.00%
lying down	0.69	0.80	0.74	0.68	0.80	0.73	0.00%
sitting	0.53	0.45	0.49	0.49	0.40	0.44	-5.00%
standing	0.63	0.60	0.61	0.60	0.56	0.58	-3.50%
Accuracy			0.69			0.67	(n=752)
Macro avg	0.70	0.71	0.70	0.67	0.69	0.68	
Weighted avg	0.68	0.69	0.69	0.66	0.67	0.66	

Tabel 10 menjelaskan bahwa SVM mengalami kesulitan terbesar pada kelas *sitting* (*recall* 0.45 dengan PP, 0.40 tanpa PP) dan *standing* (*recall* 0.60 dengan PP, 0.56 tanpa PP). Kedua kelas ini memiliki kemiripan visual yang tinggi dari sudut pandang kamera atas postur tubuh setengah badan saat duduk dan berdiri menghasilkan distribusi gradien yang serupa pada representasi HOG, sehingga



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

batas keputusan SVM sulit terbentuk dengan baik. Hal ini dikonfirmasi oleh nilai *Best CV Score* yang rendah (66.73% dengan PP, 63.51% tanpa PP) bahkan setelah pencarian *hyperparameter* intensif menggunakan *RandomizedSearchCV* dengan 30 kombinasi.

Train accuracy SVM mencapai 100% pada kedua kondisi sementara *test accuracy* hanya 67–69%, menghasilkan *train-test gap* sebesar ~31–33%. Gap yang sangat besar ini mengindikasikan *overfitting* berat model SVM menghafal pola *training* namun gagal melakukan generalisasi. Nilai *macro average recall* sebesar 71% (dengan PP) dan 69% (tanpa PP) mengonfirmasi bahwa performa rendah pada kelas *sitting* dan *standing* menekan rata-rata keseluruhan model, sementara *weighted average recall* (69% dan 67%) yang mendekati nilai *accuracy* menunjukkan bahwa distribusi kelas pada test set relatif seimbang sehingga penurunan performa bukan disebabkan oleh ketimpangan jumlah sampel antar kelas *Bottleneck* utama bukan pada *hyperparameter* melainkan pada keterbatasan mendasar representasi fitur HOG+Edge+LBP (5.870 dimensi total) dalam menangkap fitur hierarkis yang diperlukan untuk membedakan postur tubuh yang ambigu secara visual.

Hasil evaluasi HOG+SVM yang menunjukkan akurasi hanya 69,28% dengan indikasi *severe overfitting* (akurasi latih 100%) sejalan dengan temuan dalam literatur. (Hu *et al.*, 2023) dalam penelitiannya tentang deteksi okupansi berbasis CCTV juga melaporkan bahwa pendekatan *machine learning* klasik seperti SVM memiliki performa yang lebih rendah pada data yang bising dan kompleks dibandingkan dengan pendekatan *deep learning*. Dalam studi tersebut, metode *background subtraction* berbasis *Gaussian Mixture Model* dan SVM menunjukkan keterbatasan signifikan dalam menangani variasi pencahayaan dan okklusi antar penghuni. (Hu *et al.*, 2023) juga mencatat bahwa SVM cenderung mengalami penurunan performa ketika jumlah fitur melebihi jumlah sampel atau ketika terdapat *noise* dalam dataset, yang mengkonfirmasi pola *overfitting* yang diamati pada penelitian ini (akurasi latih 100% vs akurasi uji 69,28%). Hal ini memperkuat kesimpulan bahwa keterbatasan utama sistem terletak pada kualitas representasi fitur, bukan pada pilihan pengklasifikasi.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 11 *Classification Report* per Kelas MobileNetV2

Kelas	<i>Precision</i>	<i>Recall</i>	F1	<i>Precision</i>	<i>Recall</i>	F1	Delta <i>Recall</i>
	(dengan PP)	(dengan PP)	(dengan PP)	(tanpa PP)	(tanpa PP)	(tanpa PP)	
empty_room	1.00	1.00	1.00	1.00	1.00	1.00	0.00%
lying_down	0.96	0.97	0.96	0.99	0.94	0.97	-3.00%
sitting	0.89	0.99	0.94	0.88	1.00	0.93	+1.00%
standing	0.98	0.87	0.92	0.99	0.92	0.96	+5.00%
<i>Accuracy</i>			0.95			0.96	(n=752)
Macro avg	0.96	0.96	0.95	0.97	0.96	0.96	
Weighted avg	0.95	0.95	0.95	0.97	0.96	0.96	

MobileNetV2 menunjukkan performa yang jauh superior pada seluruh kelas (Tabel 11). Kelas *sitting* yang menjadi titik lemah SVM justru mencapai *recall* 0.99–1.00 pada MobileNetV2, mengkonfirmasi bahwa fitur hierarkis yang dipelajari oleh jaringan konvolusi dalam dapat membedakan postur yang ambigu dengan jauh lebih efektif dibanding fitur *hand-crafted* HOG. Fenomena menarik terjadi pada MobileNetV2 tanpa *pre-processing* model menghasilkan akurasi lebih tinggi (96.14%) dibanding dengan *pre-processing* (95.21%). Nilai *macro average F1-score* sebesar 0,95 (dengan PP) dan 0,96 (tanpa PP), yang hampir setara dengan nilai *accuracy* dan *weighted average* pada kedua kondisi, mengonfirmasi bahwa performa tinggi MobileNetV2 konsisten di seluruh kelas dan tidak didominasi oleh satu kelas mayoritas. Hal ini disebabkan oleh bobot *pretrained ImageNet* yang sudah sangat kuat, sehingga augmentasi tambahan justru berpotensi memperkenalkan noise yang tidak perlu pada *dataset* yang sudah cukup bersih.


Superioritas MobileNetV2 dibandingkan HOG+SVM dalam penelitian ini sejalan dengan temuan dalam literatur terkini. (Navid, Mahdi and Behrooz, 2025) dalam pengembangan model Attention-HAR juga melaporkan bahwa pendekatan *deep learning* dengan mekanisme perhatian secara konsisten mengungguli metode klasik berbasis fitur *handcrafted*. Dalam penelitian tersebut, model *Attention-HAR* berhasil mencapai akurasi 97,61% pada dataset UCF-101, dengan *precision* 97,95%



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dan *recall* 97,49%, yang menunjukkan kemampuan *deep learning* dalam menangkap pola *spasial-temporal* yang kompleks. Keunggulan ini terutama terlihat pada kelas-kelas aktivitas yang memiliki kemiripan visual tinggi, seperti yang juga ditemukan pada penelitian ini di mana MobileNetV2 berhasil mengklasifikasikan kelas *sitting* dengan *recall* 0,99-1,00, jauh melampaui SVM yang hanya mencapai 0,45-0,40. Hal ini mengkonfirmasi bahwa representasi fitur hierarkis yang dipelajari oleh jaringan konvolusi dalam lebih efektif dalam membedakan postur yang ambigu dibandingkan fitur *hand-crafted* HOG+Edge+LBP.



Gambar 4.6 Grafik Perbandingan Akurasi SVM vs MobileNetV2 per Kelas

Berdasarkan hasil komparatif ini, MobileNetV2 dengan pendekatan *transfer learning* dipilih sebagai model *computer vision* dalam sistem *Smart lighting indoor*, karena merupakan satu-satunya pendekatan yang berhasil melampaui target akurasi 85% yang ditetapkan (Gambar 4.6).

4.3.3 Penanganan *Domain gap* dengan Data Domain-Specific

Setelah model V5c diintegrasikan dengan sistem kamera Tapo C200, ditemukan permasalahan *domain gap* model yang dilatih menggunakan *dataset* benchmark menunjukkan performa tidak optimal pada kondisi deployment nyata. Pada pengujian awal, sistem baru dapat mendeteksi aktivitas secara konsisten ketika jarak subjek ke kamera mencapai sekitar 3–4 meter. Kondisi ini tidak dapat



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dipenuhi pada ruang uji berukuran 4×2 meter dengan kamera terpasang di dinding, karena jarak maksimum yang tersedia hanya sekitar 2 meter.

Penyebab *domain gap* ini adalah perbedaan distribusi visual antara *dataset* HAR *Indoor* yang bersumber dari Kaggle (direkam dengan jarak kamera lebih jauh dan sudut berbeda) dengan kondisi kamar tidur sebenarnya (kamera terpasang di dinding pojok ruangan, jarak dekat, sudut atas). Perbedaan jarak ini menyebabkan proporsi tubuh dalam frame berbeda signifikan subjek tampak lebih besar mengisi frame pada kondisi deployment dibanding pada *dataset training*. Setelah dikonsultasikan dengan dosen pembimbing, diputuskan untuk mengatasi *domain gap* ini melalui pengumpulan data domain-specific dari environment deployment sesungguhnya, yang dikategorikan sebagai domain adaptation.

A. Proses Pembuatan *Dataset* Domain-Specific

Dataset domain-specific dibuat menggunakan kamera Tapo C200 yang sudah terpasang di posisi deployment final dinding pojok kamar tidur berukuran 4×2 meter. Perekaman dilakukan langsung melalui stream RTSP kamera menggunakan script Python yang dibangun khusus untuk sesi perekaman ini. Setiap frame yang direkam dirotasi 90 derajat berlawanan arah jarum jam (ROTATE_90_COUNTERCLOCKWISE) untuk mengoreksi orientasi kamera yang terpasang secara vertikal di dinding.

Proses perekaman menggunakan antarmuka interaktif berbasis OpenCV yang memungkinkan peralihan kelas secara fleksibel selama sesi berlangsung. Setiap video direkam dengan durasi 5 detik pada 24 FPS, menghasilkan sekitar 120 frame per video. Sebelum setiap rekaman dimulai, terdapat jeda countdown 3 detik untuk mempersiapkan posisi subjek. Video disimpan dalam format AVI menggunakan codec XVID dengan resolusi native kamera setelah rotasi.


Variasi yang diterapkan selama perekaman mencakup variasi posisi subjek dalam ruangan untuk setiap kelas aktivitas, sehingga model tidak hanya mengenali satu posisi tetap tetapi juga variasi lokasi subjek dalam frame. Seluruh perekaman dilakukan oleh satu subjek (peneliti sendiri) dalam kondisi pencahayaan ruangan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

yang bervariasi secara alami sesuai waktu perekaman, menggunakan antarmuka yang ditunjukkan pada Gambar 4.7.



Gambar 4.7 Antarmuka Sesi Perekaman *Dataset* Tapo

B. Ekstraksi Frame dan Distribusi *Dataset*

Dari setiap video yang direkam, dilakukan ekstraksi sebanyak 8 frame menggunakan strategi evenly spaced frame diambil pada posisi yang terdistribusi merata sepanjang durasi video (zona 5%–90%) untuk memastikan representasi temporal yang beragam. Strategi ini konsisten dengan proses ekstraksi *dataset* HAR *Indoor* (kurasi), sehingga distribusi temporal kedua sumber data dapat dibandingkan secara setara.

Hasil ekstraksi dari 21 video menghasilkan total 168 frame yang terdistribusi ke dalam empat kelas aktivitas. Distribusi tidak sepenuhnya seragam karena jumlah video per kelas disesuaikan dengan ketersediaan variasi postur yang dapat direkam secara natural dalam ruangan. Distribusi lengkap *dataset* Tapo_Record_Wall dirangkum dalam Tabel 12.

Tabel 12 Distribusi *Dataset* Domain-Specific Tapo_Record_Wall

Kelas	Video	Frame (Total)	Frame <i>Train</i>	Frame Test	Frames/Video
empty_room	3	24	20	4	8
lying_down	6	48	39	9	8
sitting	7	56	45	11	8
standing	5	40	32	8	8
TOTAL	21	168	136	32	8

Kelas sitting memiliki jumlah frame terbanyak (56 frame dari 7 video) karena aktivitas duduk memiliki variasi posisi yang lebih beragam dalam ruangan duduk di meja, di kasur, dan di lantai masing-masing menghasilkan karakteristik visual yang berbeda. Sebaliknya, kelas empty_room memiliki jumlah frame paling sedikit (24 frame dari 3 video) karena kondisi ruangan kosong relatif homogen secara visual sehingga tidak memerlukan banyak variasi.

Dataset Tapo yang terkumpul kemudian digabungkan dengan *dataset* HAR Indoor (kurasi) untuk membentuk *dataset training* gabungan pada eksperimen NB1–NB4 yang dibahas pada sub-bab berikutnya. Penggabungan ini bertujuan agar model dapat mengenali aktivitas manusia baik pada distribusi visual *dataset* benchmark maupun pada distribusi visual kondisi deployment nyata secara sekaligus.


Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.8 Sampel Frame *Dataset Domain Specific Tapo_Record_Wall* per Kelas

Gambar 4.8 menampilkan sampel frame hasil ekstraksi dari *dataset* domain-specific *Tapo_Record_Wall*, masing-masing delapan sampel per kelas. Seluruh frame diambil dari sudut kamera Tapo C200 yang terpasang di dinding kamar dengan orientasi vertikal setelah koreksi rotasi 90° berlawanan arah jarum jam. Terlihat bahwa setiap kelas memiliki karakteristik visual yang berbeda dari sudut pandang kamera atas ruangan kosong (baris 1), postur duduk (baris 2), postur berdiri (baris 3), dan postur berbaring (baris 4) yang menjadi dasar pembeda antar kelas dalam proses klasifikasi.

4.3.4 Eksperimen *Fine-tuning* dengan *Dataset Gabungan* (NB1-NB4)

Untuk menentukan strategi terbaik dalam menggabungkan data Tapo dengan *dataset* V5c, dilakukan empat eksperimen dengan variasi pada dua dimensi: (1) strategi inisialisasi bobot *training* dari awal (*scratch*) vs *fine-tuning* dari *checkpoint* V5c, dan (2) komposisi *dataset* menggunakan seluruh data V5c (*full*) vs data V5c yang diseimbangkan dengan jumlah Tapo (*balanced*, 75 gambar per kelas).



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 13 Rangkuman Hasil Eksperimen NB1-NB4

NB	Konfigurasi	Dataset Train	Test Acc	Train Acc	Gap	Best Epoch	Cohen's Kappa
NB1	Scratch Full <i>Training</i> dari awal, seluruh data V5c + Tapo_Wall	2.994 gambar	95.66%	98.66%	3.00%	40/40	0.9419
NB2	Scratch Balanced <i>Training</i> dari awal, V5c 75 gambar/kelas + Tapo_Wall	376 gambar	93.48%	94.15%	0.67%	38/55	0.9125
NB3	Finetune Full <i>Fine-tune</i> dari checkpoint V5c, seluruh data V5c + Tapo_Wall	2.994 gambar	95.41%	98.86%	3.46%	22/30	0.9385
NB4	Finetune Balanced <i>Fine-tune</i> dari checkpoint V5c, V5c 75 gambar/kelas + Tapo_Wall	376 gambar	97.83%	93.09%	- 4.74%*	8/30	0.9709


Train-test gap negatif pada NB4 (-4,74%) merupakan artefak statistik yang disebabkan oleh ukuran dataset *balanced* yang sangat kecil, yakni 376 gambar *train* dan 92 gambar *test* (Tabel 13).

Seluruh empat model menunjukkan nilai *Cohen's Kappa* pada kategori *almost perfect* ($\kappa > 0,80$) menurut interpretasi Landis dan Koch (1977). NB4 mencatatkan κ tertinggi (0,9709), sejalan dengan akurasi *test set*-nya yang juga tertinggi, namun sebagaimana dijelaskan di atas, angka ini kurang dapat diandalkan sebagai indikator performa *deployment* akibat ukuran *dataset* test yang kecil dan *train-test gap* negatif yang mengindikasikan *variance* evaluasi tinggi, sebagaimana divisualisasikan pada Gambar 4.9.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan da... menyebutkan sumber :
- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.9 Grafik Perbandingan Akurasi NB1-NB4



Gambar 4.10 Training History NB3 (Finetune Full)

Model NB3 (*Finetune Full*, 95,41%) dipilih sebagai model *deployment* meskipun NB4 (*Finetune Balanced*) mencapai akurasi *test set* lebih tinggi (97,83%). Keputusan ini didasarkan pada dua pertimbangan teknis. Pertama, NB3 dilatih dengan *dataset* penuh (2.994 gambar) yang mencakup seluruh variasi visual V5c, sehingga representasi domain yang lebih kaya menghasilkan generalisasi yang lebih stabil pada kondisi *real-world* yang beragam. Kedua, NB4 menunjukkan *train-test gap* negatif yang mengindikasikan evaluasi pada *dataset* kecil dengan *variance* tinggi, sehingga angka 97,83% kurang dapat diandalkan sebagai indikator performa *deployment* yang sesungguhnya. Pada pengujian empiris langsung di kamar tidur, NB3 menunjukkan stabilitas prediksi yang lebih baik dibanding NB4.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 14 *Classification Report Model NB3 (Model Final)*


Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
empty_room	1.0000	1.0000	1.0000
lying_down	0.9612	0.9474	0.9542
sitting	0.9401	0.9668	0.9533
standing	0.9268	0.9135	0.9201
<i>Accuracy</i>			0.9541
Macro avg	0.9570	0.9569	0.9569
Weighted avg	0.9541	0.9541	0.9540

Tabel 14 menunjukkan performa model NB3 yang seimbang di seluruh kelas dengan *recall* terendah pada kelas *standing* (91,35%). Hal ini konsisten dengan karakteristik *dataset* kelas *standing* memiliki variasi postur paling tinggi dan paling rentan terhadap ambiguitas visual dengan kelas lainnya, terutama saat subjek berada di posisi tertentu dalam *frame*. Kelas *empty_room* mencapai *precision* dan *recall* sempurna 1,0000, mengkonfirmasi bahwa representasi visual ruangan kosong cukup distinktif untuk selalu terklasifikasi dengan benar. Nilai *macro average F1-score* sebesar 0,9569 dan *weighted average F1-score* sebesar 0,9540 keduanya mendekati nilai *overall accuracy* 95,41% mengonfirmasi bahwa performa tinggi model NB3 terdistribusi merata di seluruh kelas dan tidak bergantung pada dominasi kelas tertentu, sekaligus melampaui target minimum akurasi 85% yang ditetapkan pada KNF-01.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.11 *Confusion matrix* Model NB3 (Model Final)

Sebagai verifikasi silang terhadap nilai yang telah dilaporkan pada Tabel 13, *Cohen's Kappa* model NB3 dihitung ulang secara spesifik menggunakan *sklearn.metrics.cohen_kappa_score* terhadap hasil prediksi model pada *test set* berdasarkan *confusion matrix* pada Gambar 4.11, dan diperoleh $\kappa = 0,9385$ — konsisten dengan nilai pada Tabel 13. Berdasarkan interpretasi (Landis and Koch, 1977), nilai tersebut termasuk kategori *almost perfect*, yang menunjukkan bahwa kesepakatan antara prediksi model dan label sebenarnya jauh melampaui kesepakatan yang terjadi secara kebetulan.

4.3.5 Analisis Perbandingan Strategi *Transfer learning*

Untuk memahami sejauh mana proses *fine-tuning* berkontribusi terhadap performa model, dilakukan eksperimen tambahan menggunakan strategi *feature extraction only*. Pada strategi ini, seluruh *layer* pretrained MobileNetV2 dibekukan sehingga tidak ada pembaruan bobot pada *layer* konvolusi ImageNet hanya classifier head yang dilatih. *Dataset* yang digunakan identik dengan eksperimen sebelumnya (V5c gabungan Tapo_Wall, 2.994 gambar *train*, 784 gambar *test*) agar perbandingan bersifat *apples-to-apples*. Hasil perbandingan kedua strategi dirangkum pada Tabel 15.



Hak Cipta :


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 15 Perbandingan Strategi *Feature Extraction Only* dan *Fine-tune*

Strategi	Parameter Trainable	Akurasi Test	Train Acc (Best Epoch)	Train-test gap
<i>Feature Extraction Only</i>	328.964 (12,9%)	83,29%	73,35%	-9,94%
<i>Fine-tuning</i> (Model Final)	~1.200.000 (47,0%)	95,41%	98,86%	+3,46%

Hasil menunjukkan bahwa strategi *feature extraction only* hanya mampu mencapai akurasi 83,29% tidak memenuhi target minimum 85% yang ditetapkan dan tertinggal 12,12 poin persentase dari model *fine-tuned*. Kurva *training* pada Gambar 4.12 memperlihatkan bahwa akurasi test cenderung berfluktuasi dan tidak konvergen secara stabil sepanjang 30 *epoch*, berbeda dengan kurva *fine-tuning* yang menunjukkan konvergensi lebih mulus. Hal ini mengindikasikan bahwa representasi fitur ImageNet tidak dapat ditransfer secara langsung ke domain klasifikasi aktivitas manusia *indoor* tanpa adaptasi lebih lanjut melalui pembaruan bobot *layer* konvolusi.

Training History - FeatureExtraction_Only_V5c_TapoWall
Best Test Acc: 83.29% (Epoch 21/30)



Gambar 4.12 Training History Feature Extraction Only


Analisis per kelas pada Gambar 4.12 memperjelas pola ini. Kelas *empty_room* mencapai akurasi sempurna 100% pada kedua strategi, karena representasi visual ruangan kosong sudah cukup distinktif bagi bobot ImageNet tanpa perlu adaptasi. Sebaliknya, kelas *standing* mengalami penurunan akurasi paling signifikan dari



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

91,35% pada model *fine-tuned* menjadi hanya 67,31% pada *feature extraction only* dengan 55 dari 208 sampel salah diklasifikasikan sebagai *sitting*. Pola misklasifikasi ini mengonfirmasi bahwa perbedaan postur berdiri dan duduk membutuhkan fitur domain-spesifik pada level representasi konvolusi yang hanya dapat dipelajari melalui *fine-tuning*.



Gambar 4.13 *Confusion matrix Feature Extraction Only*

Fenomena *train-test gap* negatif sebesar -9,94% pada eksperimen ini, sebagaimana tampak pada Gambar 4.13, terjadi karena akurasi *training* (73,35%) lebih rendah dari akurasi test (83,29%) bukan indikasi performa yang lebih baik, melainkan merupakan artefak dari penerapan augmentasi data agresif pada set *training* (ColorJitter, RandomRotation, RandomErasing) yang tidak diterapkan pada set test, sehingga data *training* secara artifisial lebih sulit bagi model yang kapasitas adaptasinya dibatasi hanya pada classifier head.

Hasil eksperimen ini memperkuat justifikasi penggunaan strategi *fine-tuning* dalam penelitian ini. *Domain gap* antara bobot pretrained ImageNet dan karakteristik visual *dataset* aktivitas manusia *indoor* terbukti cukup signifikan sehingga adaptasi melalui *fine-tuning layer* konvolusi merupakan keharusan untuk mencapai performa yang memadai, bukan sekadar optimasi tambahan.

4.3.6 Explainable AI: Analisis Grad-CAM

Untuk memahami mengapa model MobileNetV2 NB3 menghasilkan prediksi tertentu, dilakukan analisis explainabilitas menggunakan metode Grad-CAM (Gradient-weighted Class Activation Mapping). Grad-CAM bekerja dengan




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

menghitung gradien dari output prediksi terhadap feature map pada *layer* konvolusi terakhir (features[18] pada MobileNetV2), kemudian menghasilkan heatmap yang menunjukkan area dalam gambar yang paling berpengaruh terhadap keputusan klasifikasi model.

Pada heatmap Grad-CAM, warna merah dan kuning menandakan area dengan aktivasi tinggi (area yang paling diperhatikan model), sedangkan warna biru menandakan area dengan aktivasi rendah (area yang diabaikan model). Analisis ini dilakukan terhadap sampel dari keempat kelas aktivitas menggunakan model NB3 yang sudah di-deploy.



Gambar 4.14 Hasil Grad-CAM per Kelas Model NB3



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Berdasarkan hasil visualisasi Grad-CAM pada Gambar 4.14, dapat diobservasi pola aktivasi yang berbeda untuk setiap kelas aktivitas. Pada kelas *empty_room*, model cenderung memperhatikan area keseluruhan ruangan termasuk elemen-elemen latar seperti kasur, meja, dan dinding hal ini logis karena ketidakhadiran tubuh manusia adalah fitur utama yang perlu dikenali. Pada kelas *lying_down*, aktivasi terkonsentrasi pada area horizontal yang merepresentasikan tubuh berbaring, khususnya torso dan area kasur di sekitarnya. Pada kelas *sitting*, model fokus pada area tubuh bagian atas dan interaksi antara tubuh dengan kursi atau meja. Pada kelas *standing*, aktivasi tersebar pada area tubuh tegak secara vertikal.

Pola aktivasi yang konsisten dengan fitur visual yang relevan ini mengkonfirmasi bahwa model NB3 tidak hanya mencapai akurasi tinggi, tetapi juga mempelajari representasi yang bermakna secara semantis. Model tidak bergantung pada fitur artefak seperti warna dinding atau pencahayaan ruangan, melainkan pada fitur postur tubuh yang sebenarnya hal ini meningkatkan keyakinan bahwa model akan melakukan generalisasi dengan baik pada variasi kondisi lingkungan yang berbeda. Hasil Grad-CAM juga memberikan penjelasan kualitatif mengapa MobileNetV2 jauh lebih unggul dibanding SVM+HOG dalam penelitian ini. SVM menggunakan fitur global yang diekstrak secara seragam dari seluruh gambar (HOG pada grid 64×64 piksel), sehingga tidak dapat melakukan perhatian selektif pada area tubuh yang relevan. MobileNetV2, melalui mekanisme konvolusi hierarkis, secara otomatis belajar untuk fokus pada area yang paling diskriminatif untuk setiap kelas sebuah kemampuan yang tidak dapat direplikasi oleh pendekatan fitur hand-crafted.

4.3.7 Implementasi Integrasi IoT

Setelah model final (NB3) ditetapkan, dilakukan implementasi integrasi seluruh komponen sistem IoT yang mencakup server *inference*, mikrokontroler ESP32, sensor LDR, dan aktuator lampu.

Server *inference* diimplementasikan menggunakan FastAPI pada Ubuntu Server, mengekspos endpoint HTTP GET `/stream-predict` yang melakukan pengambilan frame dari stream RTSP kamera Tapo C200, preprocessing (rotate dan resize ke 224×224), *inference* menggunakan model NB3, dan mengembalikan hasil prediksi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dalam format JSON. Model dimuat sekali saat server dijalankan dan disimpan dalam memori untuk meminimalkan latensi *inference*.

Firmware ESP32 diimplementasikan dengan tiga komponen utama yang berjalan secara siklikal setiap 10 detik: (1) polling HTTP ke endpoint server untuk mendapatkan prediksi aktivitas terkini, (2) pembacaan nilai ADC dari sensor LDR pada pin GPIO 32, dan (3) eksekusi *rule-based decision* yang menghasilkan perintah ke relay (GPIO 26) dan AC dimmer RobotDyn (GPIO 4 untuk zero-crossing, GPIO 5 untuk PSM).

Interval polling 10 detik dipilih sebagai keseimbangan antara responsivitas sistem dan beban komputasi server. Interval yang terlalu pendek berpotensi menyebabkan antrian request pada server *inference* berbasis CPU, sementara interval yang terlalu panjang menurunkan responsivitas sistem terhadap perubahan aktivitas pengguna.






© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.15 Foto Implementasi Perangkat Keras Sistem

Gambar 4.15 menunjukkan implementasi fisik perangkat keras sistem *Smart lighting indoor*. Komponen yang terlihat dari kiri ke kanan meliputi: lampu *filament* 60W E27 2900K yang terpasang pada *fitting* lampu (kiri bawah), AC Dimmer RobotDyn berwarna biru (tengah) yang terhubung ke jalur AC lampu untuk mengontrol intensitas cahaya, modul relay 1 channel berwarna merah (kanan tengah) untuk kontrol ON/OFF lampu, mikrokontroler ESP32 yang terpasang pada *breadboard* (kanan) sebagai pusat kendali sistem, serta kabel-kabel *jumper* yang menghubungkan seluruh komponen sesuai dengan pin mapping yang telah dirancang. Seluruh rangkaian dihubungkan ke jaringan listrik AC 220V melalui AC dimmer dan relay, sementara ESP32 mendapat daya dari koneksi USB ke laptop.

Jurusan Teknik Informatika dan Komputer – Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.4 Pengujian

Tahap pengujian dilakukan untuk memverifikasi bahwa sistem *Smart lighting indoor* yang dikembangkan memenuhi seluruh kebutuhan fungsional dan non-fungsional yang telah ditetapkan. Pengujian dibagi menjadi tiga bagian yang mencakup aspek berbeda dari sistem: akurasi model pada kondisi *real-world*, kesesuaian logika *rule-based*, dan integrasi keseluruhan komponen secara *end-to-end*.

4.4.1 Deskripsi Pengujian

Pengujian sistem *Smart lighting indoor* dilakukan dalam tiga tahap yang masing-masing memiliki tujuan dan metode yang berbeda, sebagaimana dirangkum dalam Tabel 16.

Tabel 16 Deskripsi Pengujian Sistem

No	Pengujian	Tujuan	Metode
1	Akurasi Model CV <i>Real-world</i>	Memverifikasi akurasi model NB3 pada kondisi deployment nyata dengan kamera terpasang di dinding	Pengujian kuantitatif: 10 percobaan per kelas × 4 kelas = 40 total, hasil dibandingkan dengan ground truth
2	Kesesuaian <i>Rule-based Decision</i>	Memverifikasi bahwa logika <i>rule-based</i> ESP32 menghasilkan keputusan lampu yang sesuai untuk setiap kombinasi input	Observasi per skenario: 8 skenario kombinasi aktivitas × kondisi LDR, dicatat kesesuaian dengan ekspektasi
3	Integrasi <i>End-to-end</i>	Memverifikasi bahwa seluruh komponen sistem bekerja secara terintegrasi pada skenario penggunaan realistis	Simulasi skenario penggunaan kamar tidur berurutan: 6 skenario dari masuk hingga keluar kamar

Ketiga pengujian ini bersifat komplementer. Pengujian 1 memverifikasi komponen *computer vision* secara terisolasi, Pengujian 2 memverifikasi komponen *rule-based* secara terisolasi, dan Pengujian 3 memverifikasi integrasi keseluruhan sistem dalam skenario penggunaan nyata.

4.4.2 Prosedur Pengujian

A. Prosedur Pengujian 1: Akurasi Model CV *Real-world*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Prosedur pengujian akurasi model CV pada kondisi *real-world* ditunjukkan pada Tabel 17.

Tabel 17 Prosedur Pengujian 1

No	Langkah Prosedur
1	Pastikan server <i>inference</i> (Ubuntu Server) berjalan dan endpoint /stream-predict dapat diakses dari jaringan lokal.
2	Pastikan kamera Tapo C200 terpasang di posisi deployment (dinding kamar) dan stream RTSP aktif.
3	Pastikan ESP32 terhubung ke jaringan WiFi yang sama dengan server <i>inference</i> .
4	Untuk setiap kelas aktivitas (empty_room, sitting, standing, lying_down): peragakan aktivitas di depan kamera selama minimal 3 detik, kemudian catat hasil prediksi yang ditampilkan melalui endpoint /predict.
5	Lakukan 10 kali percobaan per kelas dengan variasi posisi dan postur yang wajar dalam ruangan.
6	Catat prediksi sistem, <i>confidence score</i> , dan kesesuaian dengan ground truth untuk setiap percobaan.
7	Hitung akurasi per kelas dan akurasi keseluruhan, bandingkan dengan target minimum 85%.

B. Prosedur Pengujian 2: Kesesuaian *Rule-based Decision*

Prosedur pengujian kesesuaian *rule-based decision* ditunjukkan pada Tabel 18.

Tabel 18 Prosedur Pengujian 2

No	Langkah Prosedur
1	Pastikan sistem berjalan <i>end-to-end</i> (server <i>inference</i> , ESP32, relay, dan AC dimmer aktif).
2	Untuk setiap skenario: kondisikan aktivitas sesuai kelas yang diuji, lalu simulasikan kondisi LDR (terang: arahkan flash ponsel ke sensor; gelap: tutup sensor dengan tangan).
3	Amati keputusan lampu yang dieksekusi sistem (ON/OFF/DIM) dan bandingkan dengan ekspektasi <i>rule-based</i> .
4	Catat hasil pada tabel observasi beserta keterangan apabila terdapat ketidaksesuaian.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

No	Langkah Prosedur
5	Hitung persentase kesesuaian keseluruhan dari 8 skenario yang diuji.

C. Prosedur Pengujian 3: Integrasi *End-to-end*

Prosedur pengujian integrasi *end-to-end* ditunjukkan pada Tabel 19.

Tabel 19 Prosedur Pengujian 3

No	Langkah Prosedur
1	Pastikan seluruh komponen sistem aktif: server <i>inference</i> , kamera Tapo, ESP32, relay, AC dimmer, dan lampu <i>real-time</i> terpasang.
2	Lakukan simulasi skenario penggunaan kamar tidur secara berurutan sesuai tabel skenario <i>end-to-end</i> .
3	Untuk setiap skenario, beri jeda minimal 15 detik (1–2 siklus polling) agar sistem memiliki waktu untuk menghasilkan prediksi dan mengeksekusi keputusan.
4	Amati dan catat prediksi aktivitas yang dihasilkan sistem, keputusan lampu yang dieksekusi, dan kondisi fisik lampu.
5	Evaluasi kesesuaian antara skenario, prediksi sistem, dan kondisi lampu yang diharapkan.

4.4.3 Data Hasil Pengujian

A. Hasil Pengujian 1: Akurasi Model CV *Real-world*

Pengujian dilakukan dengan 10 percobaan per kelas secara langsung di depan kamera Tapo C200 yang terpasang di dinding kamar. Hasil pengujian dirangkum dalam Tabel 20.

Tabel 20 Hasil Pengujian 1 Akurasi Model CV per Kelas

No	Kelas Aktivitas	Benar / Total	Akurasi	Avg Confidence	Status Target $\geq 85\%$
1	empty_room	9 / 10	90.00%	61.48%	✓ PASS
2	sitting	10 / 10	100.00%	90.39%	✓ PASS
3	standing	7 / 10	70.00%	77.21%	X FAIL
4	lying_down	10 / 10	100.00%	83.57%	✓ PASS




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

No	Kelas Aktivitas	Benar / Total	Akurasi	Avg Confidence	Status Target $\geq 85\%$
TOTAL	Keseluruhan	36 / 40	90.00%	78.16%	✓ PASS

Sebagai ilustrasi, Gambar 4.16 menampilkan contoh *snapshot dashboard* saat sistem berhasil mengklasifikasikan masing-masing dari empat kelas aktivitas secara benar. Data kuantitatif lengkap dari 40 percobaan pengujian akurasi tetap mengacu pada Tabel 20 dan Tabel 21.



Gambar 4.16 Contoh *Output* Sistem untuk Setiap Kelas Aktivitas

Tabel 21 *Confusion matrix* Pengujian 1 (*Real-world*)

Aktual \ Prediksi	empty_room	sitting	standing	lying_down
empty_room	9	0	0	1
sitting	0	10	0	0
standing	2	1	7	0
lying_down	0	0	0	10

Distribusi kesalahan klasifikasi pada pengujian *real-world* ditunjukkan pada Tabel 21. Dari *confusion matrix* tersebut diperoleh nilai *Cohen's Kappa* sebesar 0,867 yang termasuk kategori *almost perfect* (Landis dan Koch, 1977), sehingga akurasi 90,00% yang dicapai bukan hasil kesepakatan kebetulan meskipun jumlah sampel pengujian relatif kecil ($n=40$).

B. Hasil Pengujian 2: Kesesuaian *Rule-based Decision*

Delapan skenario kombinasi aktivitas dan kondisi LDR diuji secara observasional. Kondisi LDR disimulasikan menggunakan flash ponsel (kondisi terang) dan penutupan sensor dengan tangan (kondisi gelap). Hasil pengujian dirangkum dalam Tabel 22.

Tabel 22 Hasil Pengujian 2 Observasi *Rule-based Decision*

No	Aktivitas	Kondisi LDR	Ekspektasi	Hasil Sistem	Sesuai?
1	empty_room	Terang	OFF	OFF	Ya
2	empty_room	Gelap	OFF	OFF	Ya
3	sitting	Terang	OFF	OFF	Ya
4	sitting	Gelap	ON	ON	Ya
5	standing	Terang	OFF	OFF / ON *	Kondisional
6	standing	Gelap	ON	ON	Ya
7	lying_down	Terang	DIM 15%	DIM 15%	Ya
8	lying_down	Gelap	DIM 15%	DIM 15%	Ya

Berdasarkan Tabel 22, pada beberapa percobaan model CV memprediksi *empty_room* alih-alih *standing*, sehingga lampu menjadi OFF yang kebetulan merupakan hasil yang sama. Pada percobaan lain, model memprediksi *standing* dengan benar sehingga lampu tetap OFF sesuai ekspektasi. Ketidaksesuaian bukan berasal dari logika *rule-based*, melainkan dari ketidakstabilan prediksi model CV untuk kelas *standing*.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.17 Foto Pengujian 2: Simulasi Kondisi LDR

Simulasi kondisi LDR pada Pengujian 2, sebagaimana ditunjukkan pada Gambar 4.17, dilakukan secara manual tanpa alat tambahan khusus. Untuk mensimulasikan kondisi terang, cahaya senter diarahkan langsung ke permukaan sensor LDR hingga nilai ADC terbaca di atas *threshold* 2500 (*inverted*). Untuk mensimulasikan kondisi gelap, sensor LDR ditutup menggunakan tangan bersarung hingga nilai ADC turun di bawah *threshold* 2500. Kedua kondisi berhasil memicu respons *rule-based* yang sesuai pada setiap percobaan, mengkonfirmasi bahwa sensor LDR dan *threshold* yang ditetapkan berfungsi dengan baik sebagai input tambahan sistem.

Jurusan Teknik Informatika dan Komputer – Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

C. Hasil Pengujian 3: Integrasi *End-to-end*

Enam skenario penggunaan kamar tidur diuji secara berurutan untuk mensimulasikan siklus aktivitas nyata pengguna. Setiap skenario diberi jeda minimal 15 detik untuk memastikan sistem memiliki waktu memproses minimal satu siklus polling. Hasil pengujian dirangkum dalam Tabel 23.


Tabel 23 Hasil Pengujian Integrasi *End-to-end*

No	Skenario	Prediksi Sistem	Keputusan Lampu	Kondisi Fisik	Sesuai?
1	Masuk kamar, berdiri di area kasur	standing	ON	Menyala	Ya
2	Duduk di meja kerja	standing → empty_room → sitting	ON → OFF → ON	Menyesuaikan	Akhirnya Ya
3	Cahaya siang masuk (LDR terang)	Bervariasi	OFF	Mati	Ya
4	Sore hari, cahaya berkurang (LDR gelap)	Bervariasi	Bervariasi	Menyesuaikan	Akhirnya Ya
5	Berbaring untuk istirahat	lying_down / empty_room	DIM / OFF	DIM / Mati bergantian	Tidak Konsisten
6	Keluar kamar	empty_room	OFF	Mati	Ya



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.18 Foto Pengujian 3: Sistem Berjalan *End-to-end*

Gambar 4.18 menampilkan hasil Pengujian 3 Sistem Berjalan *End-to-End*. Pada baris atas (kiri ke kanan) ditunjukkan kondisi fisik lampu OFF saat ruangan kosong terdeteksi, lampu ON saat aktivitas terdeteksi pada kondisi gelap, dan lampu DIM 15% saat *lying_down* terdeteksi; pada baris bawah ditampilkan *screenshot dashboard Smart lighting Monitor* yang menunjukkan empat kondisi pengujian: (1) *empty_room* terdeteksi dengan *confidence* 99,99%, keputusan lampu OFF; (2) subjek duduk namun sistem memprediksi *empty_room* dengan *confidence* 49,31%, keputusan lampu OFF kasus ini merupakan contoh misklasifikasi akibat posisi tubuh yang tidak mengisi *frame* secara dominan, namun keputusan lampu tetap konsisten dengan logika *rule-based* meskipun prediksi tidak akurat; (3) *lying_down* terdeteksi dengan *confidence* 57,57%, keputusan lampu DIM; (4) *standing* terdeteksi dengan *confidence* 88,09%, keputusan lampu ON.

4.4.4 Analisis dan Evaluasi Pengujian

A. Analisis Pengujian 1



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Akurasi keseluruhan sistem pada kondisi *real-world* mencapai 90.00% (36/40 percobaan benar), melampaui target minimum 85% yang ditetapkan. Terdapat *domain gap* sebesar 5.41% antara akurasi test set (95.41%) dan akurasi *real-world* (90.00%), yang merupakan fenomena umum dalam sistem *computer vision* akibat perbedaan distribusi visual antara data *training* dan kondisi deployment.

Kelas standing menjadi satu-satunya kelas yang tidak mencapai target (70.00%, 7/10). Dari *confusion matrix* pada Tabel 21, dua kesalahan terjadi ke arah empty_room dan satu kesalahan ke arah sitting. Kesalahan ke empty_room terjadi saat subjek berdiri terlalu di pinggir frame atau terlalu dekat dengan meja, sehingga proporsi tubuh dalam frame tidak cukup dominan. Kesalahan ke sitting terjadi akibat ambiguitas visual antara posisi berdiri setengah badan dengan posisi duduk dari sudut kamera atas.

Kelas sitting dan lying_down mencapai akurasi sempurna 100%, mengkonfirmasi bahwa kedua postur ini memiliki fitur visual paling distinktif dari sudut kamera terpasang di dinding. Kelas empty_room mencapai 90% dengan satu kesalahan ke lying_down yang kemungkinan terjadi pada kondisi transisi saat subjek baru meninggalkan frame. *Confidence score* rata-rata keseluruhan (78.16%) menunjukkan bahwa model masih memiliki ruang untuk peningkatan kepercayaan prediksi, terutama pada kelas empty_room (61.48%) yang memiliki *confidence* paling rendah.

B. Analisis Pengujian 2

Logika *rule-based* yang diimplementasikan di ESP32 berjalan dengan benar pada seluruh skenario. Dari 8 skenario yang diuji, 7 skenario (87.5%) menghasilkan keputusan yang sepenuhnya sesuai ekspektasi, dan 1 skenario bersifat kondisional. Tidak ditemukan kesalahan pada lapisan *rule-based* itu sendiri; keputusan lampu selalu sesuai dengan aturan yang ditetapkan berdasarkan input yang diterima.

Ketidaksesuaian pada skenario 5 (standing + terang) bersumber dari ketidakstabilan prediksi model CV untuk kelas standing, bukan dari kesalahan logika *rule-based*. Ketika model memprediksi empty_room alih-alih standing, *rule-based* secara tepat menghasilkan keputusan OFF yang merupakan keputusan yang sama dengan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

ekspektasi skenario (standing + terang → OFF). Hal ini justru menunjukkan bahwa arsitektur hybrid CV + *rule-based* memberikan redundansi yang menguntungkan: ketidakstabilan pada lapisan CV tidak selalu menghasilkan keputusan lampu yang salah.

Sensor LDR terbukti berperan signifikan sebagai komponen pelengkap. Pada skenario 3 dan 5 di mana cahaya alami sudah cukup, sensor LDR secara efektif menghasilkan keputusan OFF yang hemat energi meskipun model CV mendeteksi keberadaan manusia. Hal ini mengkonfirmasi nilai arsitektur hybrid dalam meningkatkan kecerdasan dan efisiensi sistem secara keseluruhan.

C. Analisis Pengujian 3

Dari enam skenario *end-to-end*, empat skenario (1, 3, 4, dan 6) menunjukkan kesesuaian yang baik, satu skenario (2) mencapai kesesuaian setelah beberapa siklus polling, dan satu skenario (5) menunjukkan ketidakkonsistenan yang signifikan.

Skenario 1 (masuk kamar, berdiri) dan skenario 6 (keluar kamar) berjalan tanpa hambatan karena kedua kondisi ini memiliki representasi visual yang paling jelas dari sudut kamera: subjek berdiri di area terbuka, dan ruangan kosong menghasilkan prediksi yang langsung tepat. keputusan OFF secara konsisten meskipun prediksi model CV bervariasi.

Skenario 2 (duduk di meja) dan skenario 4 (sore hari) mengalami beberapa prediksi perantara sebelum akhirnya stabil. Fenomena ini disebabkan oleh temporal instability model memproses satu frame independen tanpa konteks temporal, sehingga pergerakan kecil selama transisi postur menghasilkan frame yang ambigu. Setelah subjek diam dalam posisi final, sistem berhasil menstabilkan prediksi dan menghasilkan keputusan yang tepat.

Skenario 5 (berbaring) menunjukkan ketidakkonsistenan terbesar prediksi bergantian antara *lying_down* dan *empty_room* mengakibatkan lampu bergantian antara DIM dan OFF. Berdasarkan observasi, sistem baru stabil memprediksi *lying_down* setelah subjek diam sepenuhnya dalam posisi berbaring selama beberapa detik. Setiap pergerakan kecil seperti menggeser posisi tubuh



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

menyebabkan frame transisi yang diinterpretasikan sebagai empty_room karena proporsi tubuh dalam frame berkurang sementara.

D. Ringkasan Hasil Pengujian

Seluruh aspek pengujian yang ditetapkan berhasil dipenuhi oleh sistem, sebagaimana dirangkum dalam Tabel 24.


Tabel 24 Ringkasan Hasil Pengujian Keseluruhan

Aspek Pengujian	Target	Hasil	Keterangan	Status
Akurasi model (test set)	$\geq 85\%$	95.41% (NB3)	Diukur pada <i>dataset</i> HAR <i>Indoor</i> (kurasi) + Tapo, 784 gambar	✓
Akurasi <i>real-world</i>	$\geq 85\%$	90.00%	40 percobaan langsung di kamar, 3 dari 4 kelas $\geq 85\%$	✓
<i>Rule-based decision</i>	Sesuai aturan	7/8 skenario (87.5%)	1 skenario kondisional akibat ketidakstabilan prediksi CV pada kelas standing	✓
Integrasi IoT (<i>end-to-end</i>)	Fungsional	4/6 skenario penuh, 2 kondisional	Ketidakkonsistenan pada transisi postur dan lying_down; LDR bekerja baik	✓
Sensor LDR	Fungsional	Terverifikasi	<i>Threshold</i> inverted > 2500 = terang terkonfirmasi pada seluruh pengujian	✓
AC Dimmer (DIM 15%)	DIM saat lying_down	Terverifikasi	Intensitas 15% dengan kurva logaritmik berjalan sesuai rancangan	✓



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.19 Grafik Akurasi per Kelas: Pengujian *Real World* vs *Test Set*

Perbandingan akurasi per kelas antara pengujian *real-world* dan *test set* ditunjukkan pada Gambar 4.19. Berdasarkan Tabel 24, sistem *Smart lighting indoor* yang dikembangkan berhasil memenuhi seluruh target yang ditetapkan. Akurasi model pada *test set* mencapai 95.41% dan pada kondisi *real-world* mencapai 90.00%, keduanya melampaui target minimum 85%. *Rule-based decision* berjalan dengan tingkat kesesuaian 87.5%, dan seluruh komponen IoT terintegrasi secara fungsional dari kamera hingga aktuator lampu.

Keterbatasan utama sistem yang teridentifikasi dari hasil pengujian adalah temporal instability pada prediksi single-frame *inference*, yang menyebabkan fluktuasi keputusan lampu saat pengguna melakukan transisi postur atau pergerakan. Keterbatasan ini dapat diatasi pada pengembangan selanjutnya melalui implementasi *majority voting temporal* atau mekanisme *hysteresis* pada logika pengambilan keputusan di ESP32.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB V PENUTUP

5.1 Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, diperoleh simpulan sebagai berikut.

1. Sistem *Smart lighting indoor* berbasis *computer vision* dengan pendekatan *rule-based* berhasil dikembangkan dan diimplementasikan pada lingkungan kamar tidur berukuran 4×2 meter. Sistem mengintegrasikan kamera Tapo C200 sebagai sensor utama, sensor LDR sebagai pendeteksi kecerahan cahaya ruangan, model MobileNetV2 sebagai komponen klasifikasi aktivitas, mikrokontroler ESP32 sebagai unit kontrol, serta AC dimmer dan relay sebagai aktuator lampu dalam satu *pipeline* yang fungsional dari akuisisi citra hingga eksekusi kondisi lampu secara otomatis.
2. Hasil evaluasi komparatif menunjukkan bahwa pendekatan *deep learning* berbasis MobileNetV2 menghasilkan akurasi yang jauh lebih tinggi dibandingkan pendekatan *machine learning* berbasis HOG+SVM. Model MobileNetV2 (NB3, Finetune Full) mencapai akurasi 95,41% pada data uji, sedangkan model HOG+SVM hanya mencapai akurasi 69,28% dengan indikasi *severe overfitting* (akurasi latih 100%). Perbedaan performa ini disebabkan oleh ketidakcukupan representasi fitur handcrafted HOG dalam membedakan empat kelas aktivitas *indoor* secara diskriminatif, menjadikan kualitas representasi fitur sebagai faktor penentu yang lebih kritis dibandingkan pemilihan pengklasifikasi.
3. Pengujian model pada kondisi *real-world* menggunakan kamera yang terpasang di kamar menunjukkan akurasi keseluruhan sebesar 90,00% (36 dari 40 percobaan benar), melampaui target minimum 85% yang ditetapkan. Kelas *sitting* dan *lying_down* mencapai akurasi sempurna 100%, sedangkan kelas *standing* menjadi satu-satunya kelas yang tidak memenuhi target (70,00%) akibat ambiguitas visual pada kondisi subjek berdiri di pinggir frame atau terlalu dekat dengan meja.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4. Logika *rule-based* yang diimplementasikan pada ESP32 berjalan dengan benar pada 7 dari 8 skenario yang diuji (87,5%), dengan 1 skenario bersifat kondisional akibat ketidakstabilan prediksi model *computer vision* pada kelas standing. Sensor LDR terbukti memberikan kontribusi signifikan sebagai komponen pelengkap: pada kondisi cahaya alami mencukupi, sensor LDR secara efektif menghasilkan keputusan OFF terlepas dari hasil klasifikasi aktivitas, sehingga meningkatkan efisiensi energi sistem secara keseluruhan.
5. Pengujian integrasi *end-to-end* menunjukkan bahwa sistem mampu berjalan secara fungsional pada skenario penggunaan nyata. Keterbatasan utama yang teridentifikasi adalah temporal instability pada inferensi single-frame, yang menyebabkan fluktuasi keputusan lampu pada kondisi transisi postur pengguna, khususnya pada skenario berbaring.

5.2 Saran

Berdasarkan keterbatasan yang ditemukan selama penelitian, beberapa saran dikemukakan untuk pengembangan sistem lebih lanjut.

Untuk mengatasi ketidakstabilan prediksi pada kondisi transisi postur, disarankan agar pengembangan selanjutnya mengimplementasikan mekanisme majority voting temporal, di mana keputusan akhir didasarkan pada kelas yang paling sering muncul dalam beberapa frame berurutan, atau mekanisme hysteresis pada logika ESP32 yang mensyaratkan konsistensi prediksi selama sejumlah siklus sebelum keputusan lampu dieksekusi.

Peningkatan akurasi pada kelas standing dapat dilakukan melalui augmentasi *dataset* dengan variasi posisi tubuh di tepi frame, atau melalui penyesuaian sudut dan posisi pemasangan kamera agar area tangkapan lebih mencakup seluruh zona aktivitas ruangan.

Penambahan mekanisme *smoothing* pada pembacaan sensor LDR, seperti moving average atau debouncing berbasis waktu, disarankan untuk mencegah fluktuasi keputusan lampu akibat perubahan intensitas cahaya yang bersifat sementara, misalnya yang disebabkan oleh bayangan sesaat.

Untuk pengembangan pada skala yang lebih luas, arsitektur sistem dapat dikembangkan dengan menambahkan kemampuan multi-zona melalui penggunaan



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

lebih dari satu kamera, serta integrasi dengan platform manajemen bangunan atau antarmuka kontrol berbasis aplikasi mobile untuk memungkinkan pemantauan dan konfigurasi sistem secara jarak jauh.





Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR PUSTAKA

- Al-Hafiz, A.Y. *et al.* (2025) *IMPLEMENTASI SMART LIGHTING BERBASIS SENSOR CAHAYA DAN SENSOR AIR UNTUK RESPON LINGKUNGAN BERBASIS ARDUINO-UNO*, *Jurnal Multidisiplin Inovatif*. Available at: <https://sejurnal.com/pub/index.php/jmi/article/view/6948> (Accessed: January 16, 2026).
- Alnattah, A. *et al.* (2025) “Artificial Intelligence in Clinical Decision-Making: A Scoping Review of Rule-Based Systems and Their Applications in Medicine,” *Cureus* [Preprint]. Available at: <https://doi.org/10.7759/cureus.91333>.
- Anggono, H. *et al.* (2025) “Sistem Deteksi Kehadiran Manusia dalam Ruangan Menggunakan Algoritma Histogram of Oriented Gradients,” *SMATIKA JURNAL*, 15(01), pp. 240–247. Available at: <https://doi.org/10.32664/smatika.v15i01.2077>.
- Atmaja, J.F.T., Sari, M.W. and Ciptadi, P.W. (2021) “Developing application of automatic lamp control and monitoring system using internet of things,” *Journal of Physics: Conference Series*, 1823(1), p. 012002. Available at: <https://doi.org/10.1088/1742-6596/1823/1/012002>.
- Chen, T. *et al.* (2021) “A novel face recognition method based on fusion of LBP and HOG,” *IET Image Processing*, 15(14), pp. 3559–3572. Available at: <https://doi.org/10.1049/ipr2.12192>.
- Duklan, N. *et al.* (2024) “CNN Architectures for Image Classification: A Comparative Study Using ResNet50V2, ResNet152V2, InceptionV3, Xception, and MobileNetV2,” *International Journal of Electronics and Communication Engineering*, 11(9), pp. 11–21. Available at: <https://doi.org/10.14445/23488549/IJECE-V11I9P102>.
- Gulzar, Y. (2023) “Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique,” *Sustainability*, 15(3), p. 1906. Available at: <https://doi.org/10.3390/su15031906>.
- Hu, S. *et al.* (2023) “Building Occupancy Detection and Localization Using CCTV Camera and Deep Learning,” *IEEE Internet of Things Journal*, 10(1), pp. 597–608. Available at: <https://doi.org/10.1109/JIOT.2022.3201877>.
- Kolawole, A.O., Irhebhude, M.E. and Odion, P.O. (2025) “Human Action Recognition in Military Obstacle Crossing Using HOG and Region-Based Descriptors,” *Journal of Computing Theories and Applications*, 2(3), pp. 410–426. Available at: <https://doi.org/10.62411/jcta.12195>.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Landis, J.R. and Koch, G.G. (1977) “The Measurement of Observer Agreement for Categorical Data,” *Biometrics*, 33(1), p. 159. Available at: <https://doi.org/10.2307/2529310>.

M. Khairul Anam *et al.* (2025) “Sentiment Analysis Optimization Using Ensemble of Multiple SVM Kernel Functions,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 9(4), pp. 905–914. Available at: <https://doi.org/10.29207/resti.v9i4.6708>.

Muhamad Malik Matin, I. *et al.* (2026) “Transfer learning untuk Deteksi Status Burung di Indonesia Berbasis Web,” *MULTINETICS*, 11(2), pp. 201–209. Available at: <https://doi.org/https://doi.org/10.32722/multinetics.v11i02.8149>.

Muhammad Zikri, Muhammad Fikry and Rizki Suwanda (2025) “RANCANG BANGUN SMART GREENHOUSE OTOMATIS BERBASIS INTERNET OF THINGS DENGAN KONTROL RULE-BASED UNTUK OPTIMALISASI PERTUMBUHAN TANAMAN TOMAT,” *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, 10(2), pp. 693–700. Available at: <https://doi.org/10.36341/rabit.v10i2.6435>.

Navid, R., Mahdi, R. and Behrooz, M. (2025) “Attention-HAR: Advanced Human Activity Recognition Using a Deep Learning Model with an Integrated Attention Mechanism,” *JOURNAL OF ARTIFICIAL INTELLIGENCE AND DATA MINING*, 13(3), pp. 293–304.

van Zyl, C., Ye, X. and Naidoo, R. (2023) “Harnessing eXplainable artificial intelligence for feature selection in time series energy forecasting: A comparative analysis of Grad-CAM and SHAP,” *Applied Energy*, 353, p. 122079. Available at: <https://doi.org/10.1016/j.apenergy.2023.122079>.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR RIWAYAT HIDUP

Muhamad Adnan Fadillah



Lahir di Kab. Bekasi pada tanggal 13 Mei 2004. Lulus dari Sekolah Islam, Alam dan Sains Al-Jannah tahun 2015, SMPN 196 Jakarta tahun 2019, dan SMAN 2 Gunung Putri tahun 2022. Saat ini menempuh pendidikan Diploma Empat (D4) Program Studi Teknik Informatika, Jurusan Teknik Informatika dan Komputer, Politeknik Negeri Jakarta, dan menyelesaikan skripsi berjudul "Pengembangan Sistem Smart Lighting

Indoor Berbasis Klasifikasi Aktivitas Manusia Menggunakan Computer Vision" pada tahun 2026.

**POLITEKNIK
NEGERI
JAKARTA**