



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



Judul:

**PENGEMBANGAN APLIKASI MOBILE UNTUK
EVALUASI KUALITAS GERAKAN LATIHAN
MANDIRI BERBASIS DEEP LEARNING
PADA GERAKAN PUSH-UP**

SKRIPSI

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

**POLITEKNIK
NEGERI
JAKARTA**

**MUHAMMAD RAJIFUL HAQ GEA
2207412058**

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



© Hak Cipta milik Jurusan TIK Politeknik Negeri Jakarta

Hak Cipta :

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

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertanda tangan di bawah ini:

Nama : Muhammad Rajiful Haq Gea

NIM : 2207412058

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

Judul skripsi : PENGEMBANGAN APLIKASI MOBILE UNTUK EVALUASI
KUALITAS GERAKAN LATIHAN MANDIRI BERBASIS DEEP
LEARNING PADA GERAKAN PUSH-UP

Menyatakan dengan sebenarnya bahwa skripsi ini benar-benar merupakan hasil karya saya sendiri, bebas dari penjiplakan 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 penjiplakan lain yang dianggap melanggar peraturan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Depok, 21 Juli 2026

Yang membuat pernyataan

(Muhammad Rajiful Haq Gea)

NIM.2207412058

POLITEKNIK
NEGERI
JAKARTA



© Hak Cipta milik Jurusan TIK 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 dari Jurusan TIK Politeknik Negeri Jakarta

LEMBAR PENGESAHAN

Skripsi diajukan oleh :

Nama : Muhammad Rajiful Haq Gea

NIM : 2207412058

Program Studi : TI / ~~TMD/TMI~~ *

Judul Skripsi : PENGEMBANGAN APLIKASI MOBILE UNTUK EVALUASI
KUALITAS GERAKAN LATIHAN MANDIRI BERBASIS DEEP
LEARNING PADA GERAKAN PUSH-UP

Telah diuji oleh tim penguji dalam Sidang Skripsi pada hari Rabu, tanggal 24
bulan Juni, tahun 2026 dan dinyatakan LULUS.

Disahkan oleh

Pembimbing I : Mera Kartika Delimayanti, S.Si., M.T., Ph.D. ()

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

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

Penguji III : Fajar Septian, 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 penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, dan petunjuk-Nya sehingga penulisan skripsi ini dapat diselesaikan dengan baik. Shalawat serta salam senantiasa tercurah kepada junjungan Nabi Muhammad SAW, yang menjadi suri teladan bagi seluruh umat manusia.

Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Terapan pada Program Studi Teknik Informatika, Politeknik Negeri Jakarta. Penulisan ini bertujuan untuk menyampaikan hasil penelitian serta sebagai wujud kontribusi penulis dalam pengembangan ilmu pengetahuan, khususnya di bidang penerapan teknologi deep learning untuk evaluasi kualitas gerakan push-up berbasis aplikasi mobile.

Dalam proses penyusunan skripsi ini, penulis mendapatkan banyak bantuan, dukungan, bimbingan, serta doa dari berbagai pihak. Oleh karena itu, penulis menyampaikan rasa terima kasih dan penghargaan setinggi-tingginya kepada:

1. Mera Kartika Delimayanti, S.Si., M.T., Ph.D, selaku dosen pembimbing yang telah memberikan bimbingan, arahan, dan masukan yang sangat berarti selama proses penyusunan skripsi ini dari awal hingga selesai.
2. Ibu Erita Yulianti, selaku orang tua penulis, atas cinta, doa, dan dukungan yang tiada henti yang menjadi sumber kekuatan dan motivasi terbesar dalam menyelesaikan studi ini.
3. Seluruh rekan mahasiswa Program Studi Teknik Informatika Politeknik Negeri Jakarta, atas kebersamaan, semangat, dan dukungan yang diberikan selama masa perkuliahan.
4. Aurio Hendrianoko Rajaa, Partner penulis yang selalu memberikan dukungan dan membantu proses penulis dalam menyelesaikan skripsi ini

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan untuk perbaikan di masa mendatang. Semoga skripsi ini dapat bermanfaat bagi semua pihak, serta menjadi sumbangan kecil bagi perkembangan ilmu pengetahuan, khususnya dalam bidang kecerdasan buatan dan kesehatan.



© 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

Akhir kata, penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu menyelesaikan penyusunan skripsi ini. Semoga Allah SWT senantiasa melimpahkan rahmat dan keberkahan-Nya kepada kita semua.

Depok, 4 Juni 2026

Muhammad Rajiful Haq Gea





© Hak Cipta milik Jurusan TIK 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 mengumpulkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin dari Jurusan TIK Politeknik Negeri Jakarta

**SURAT PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK
KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Politeknik Negeri Jakarta, saya bertanda

Nama Mahasiswa : Muhammad Rajiful Haq Gea
N I M : 2207412058
Jurusan/Program Studi : T. Informatika dan Komputer/Teknik Informatika

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

**PENGEMBANGAN APLIKASI MOBILE UNTUK EVALUASI KUALITAS
GERAKAN LATIHAN MANDIRI BERBASIS DEEP LEARNING PADA
GERAKAN PUSH-UP**

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 selamata tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai
pemilik Hak Cipta.

Demikian pernyataan ini Saya buat dengan sebenarnya.

Depok, 25 Juni 2026

Yang membuat pernyataan,

Muhammad Rajiful Haq Gea

NIM 2207412058



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan 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 APLIKASI MOBILE UNTUK EVALUASI KUALITAS GERAKAN *PUSH-UP* BERBASIS *DEEP LEARNING*

Abstrak

Penilaian gerakan *push-up* secara mandiri sering mengalami kendala karena keterbatasan pengawasan, sehingga kesalahan teknik sering tidak disadari dan dapat mengurangi efektivitas latihan serta meningkatkan risiko cedera. Penelitian ini bertujuan mengembangkan aplikasi evaluasi gerakan *push-up* secara *real-time* berbasis visi komputer untuk mengidentifikasi kualitas gerakan dan memberikan umpan balik terhadap kesalahan yang dilakukan pengguna. Aplikasi memanfaatkan metode MoveNet untuk mengekstraksi 17 titik *keypoint* tubuh dari setiap *frame* video, kemudian data sekuensial tersebut diproses menggunakan model Bidirectional Gated Recurrent Unit (BiGRU) untuk mengklasifikasikan gerakan *push-up* sesuai kategori yang telah ditentukan. Tahapan penelitian meliputi pengumpulan dan prapemrosesan data, ekstraksi *keypoint*, pelatihan model, serta implementasi pada aplikasi Android untuk pengujian secara *real-time*. Hasil penelitian menunjukkan bahwa aplikasi mampu melakukan klasifikasi gerakan *push-up* dan memberikan evaluasi terhadap kesalahan gerakan berdasarkan hasil deteksi model yang telah dilatih. Implementasi aplikasi pada perangkat bergerak memungkinkan pengguna memperoleh umpan balik secara langsung selama berolahraga. Penelitian ini diharapkan dapat menjadi media pendukung latihan mandiri yang membantu pengguna melakukan gerakan *push-up* dengan teknik yang lebih benar dan efektif.

Kata kunci: Android, evaluasi gerakan, GRU, MoveNet, *push-up*, *real-time*.



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	vi
<i>Abstrak</i>	vii
DAFTAR ISI.....	viii
DAFTAR GAMBAR.....	xi
DAFTAR TABEL	xii
LAMPIRAN.....	xiii
BAB I.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan dan Manfaat Penelitian	4
1.4.1 Tujuan	4
1.4.2 Manfaat	4
1.5 Sistematika Penulisan	4
BAB II	6
TINJAUAN PUSTAKA.....	6
2.2 Push-Up.....	8
2.3 Pose Estimation.....	10
2.3.1 Microsoft COCO dan Standar 17 Keypoint.....	10
2.3.2 <i>MoveNet</i>	11
2.4 Deep Learning.....	12
2.4.1 Recurrent Neural Network (RNN)	12
2.4.2 Gated Recurrent Unit (GRU)	13
2.4.3 Bidirectional GRU (<i>BiGRU</i>).....	14
2.5 Feature Engineering	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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2.6 Stratified Split (Pembagian Data Bertingkat)	18
2.7 Augmentasi Data	20
2.8 Batch Normalization	21
2.9 Label Smoothing	22
2.10 Early Stopping.....	22
2.11 Normalisasi Data	23
2.12 Evaluasi Model.....	24
2.12.1 Confusion Matrix	25
2.12.2 Accuracy	26
2.12.3 Precision.....	27
2.12.4 Recall.....	28
2.12.5 F1-Score	28
2.12.6 ROC-AUC.....	29
2.13 Kotlin	30
2.14 Black Box Testing.....	31
2.15 User Acceptance Testing (UAT).....	32
BAB III.....	25
METODE PENELITIAN	25
3.1 Rancangan Penelitian	25
A. Kebutuhan Model.....	25
3.2 Tahapan Penelitian	28
3.2.1 Identifikasi Masalah	30
3.2.2 Studi Literatur	30
3.2.3 Pengumpulan Data	31
3.2.4 Validasi Dataset	33
3.2.5 Pre-Processing Data	33
3.2.8 Integrasi dan Pengembangan Aplikasi Android.....	40
3.2.9 Pengujian (<i>Testing</i>)	41
3.2.10 Kesimpulan dan Pembuatan Laporan.....	41
BAB IV	41
HASIL DAN PEMBAHASAN	41
4.1 Dataset Penelitian.....	41



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

4.1.1 Distribusi Dataset Berdasarkan Strata.....	41
4.1.2 Validitas Stratified Split.....	42
4.2 Skenario Pengujian.....	44
4.3 Hasil Pelatihan Model.....	44
4.4 Hasil Evaluasi Model.....	47
4.4.1 Confusion Matrix.....	47
4.5 Hasil Pengembangan Aplikasi Android.....	49
4.5.1 Halaman Utama (HomeScreen).....	49
4.5.2 Halaman Panduan (<i>PushUpGuideScreen</i>).....	50
4.5.3 Halaman Tutorial (<i>PushUpTutorialScreen</i>).....	51
4.5.4.1 State IDLE.....	52
4.6 Hasil Pengujian Black Box Testing.....	55
4.7 Hasil User Acceptance Testing (UAT).....	56
4.8 Pembahasan.....	58
BAB V.....	59
PENUTUP.....	59
5.1 Simpulan.....	59
5.2 Saran.....	60
DAFTAR PUSTAKA.....	63
DAFTAR RIWAYAT HIDUP PENULIS.....	66
LAMPIRAN.....	67

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

DAFTAR GAMBAR

Gambar 2. 1 Push Up Benar.....	9
Gambar 2. 2 Push Up Salah	9
Gambar 2. 3 Visualisasi 17 Keypoint pada Tubuh Manusia.....	11
Gambar 2. 4 Arsitektur GRU dengan reset gate dan update gate	13
Gambar 2. 5 Arsitektur Bidirectional Gated Recurrent Unit (<i>BiGRU</i>).....	14
Gambar 3. 1 Rancangan Penelitian Gerakan Push.....	25
Gambar 3. 2 Pembagian Dataset	26
Gambar 3. 3 Use Case Diagram Aplikasi	27
Gambar 3. 4 Tahapan Penelitian	28
Gambar 3. 5 Arsitektur Model	38
Gambar 4. 8 <i>Confusion Matrix</i>	48
Gambar 4. 1 Halaman Utama.....	50
Gambar 4. 2 Halaman Panduan.....	51
Gambar 4. 3 Halaman Instruksi Push Up.....	52
Gambar 4. 4 Halaman Kamera(<i>Idle</i>)	53
Gambar 4. 5 Sesi Mulai Gerakan(Record).....	53
Gambar 4. 6 Hasil Evaluasi.....	54

**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 TABEL

Tabel 2. 1 Perbandingan Penelitian Terdahulu	7
Tabel 2. 2 Daftar 17 Keypoint	10
Tabel 2. 3 Deskripsi 81 Fitur per Frame	17
Tabel 2. 5 Analisis Sembilan Konfigurasi Rasio Split.....	19
Tabel 2. 6 Confusion Matrix	25
Tabel 3. 1 Distribusi Dataset Berdasarkan Sudut Pandang.....	32
Tabel 3. 2 Distribusi Dataset Berdasarkan Sumber	32
Tabel 3. 3 Rincian 81 Fitur per Frame	34
Tabel 3. 4 Pembagian Dataset.....	36
Tabel 3. 5 Perbandingan Skema 70/15/15 vs 80/10/10.....	36
Tabel 3. 6 Konfigurasi Model	39
Tabel 4. 1 Distribusi Dataset per Strata	41
Tabel 4. 2 menunjukkan hasil analisis untuk 9 konfigurasi rasio split.	43
Tabel 4. 3 Hyperparameter Pelatihan Model	45
Tabel 4. 4 Hasil Pelatihan Model BiGRU.....	46
Tabel 4. 5 Hasil Evaluasi Model	47
Tabel 4. 15 Rekapitulasi Hasil UAT.....	56

**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

LAMPIRAN

Lampiran 1 Dokumentasi Pertemuan dengan Trainer untuk Validasi Data	67
Lampiran 2 Hasil Dataset yang sudah di Validasi Oleh Trainer.....	68
Lampiran 3 Rekapitulasi Hasil Kuesioner Pengguna Aplikasi KINETIC	69
Lampiran 4 Dokumentasi Bimbingan Dengan Bu Mera Kartika Delimayanti, S.Si., M.T., Ph.D	70
Lampiran 5 Hasil Black Box Testing — Navigation Flow	71
Lampiran 6 Hasil Black Box Testing — Camera Permission	72
Lampiran 7 Hasil Black Box Testing — State IDLE.....	72
Lampiran 8 Hasil Black Box Testing – State Recording	73
Lampiran 9 Hasil Black Box Testing – State Evaluation Processing	75
Lampiran 10 Hasil Black Box Testing – State Evaluation Review	75
Lampiran 11 Hasil Black Box Testing – Guide Screen	77
Lampiran 12 Hasil Black Box Testing – Tutorial Screen	77
Lampiran 13 Hasil Black Box Testing – Edge Cases	78

**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 I PENDAHULUAN

1.1 Latar Belakang

Push-up merupakan salah satu bentuk latihan fisik yang populer dan dapat dilakukan secara mandiri tanpa memerlukan peralatan khusus maupun biaya tambahan. *Push-up* melibatkan berbagai kelompok otot utama, termasuk dada, trisep, bahu, dan otot inti, sehingga efektif untuk meningkatkan kekuatan dan daya tahan tubuh bagian atas. Menurut Winarno (2018), gerakan *push-up* yang benar dilakukan dengan menjaga posisi tubuh tetap lurus dari kepala hingga tumit, tangan diletakkan sejajar bahu, siku membentuk sudut sekitar 90 derajat saat menekuk, serta dada mendekati lantai tanpa menyentuh. Namun, efektivitas latihan *push-up* sangat bergantung pada ketepatan gerakan yang dilakukan. Kesalahan dalam teknik *push-up*, seperti posisi tubuh yang tidak lurus, sudut siku yang tidak tepat, atau pinggang yang terlalu melengkung, dapat mengurangi manfaat latihan dan bahkan meningkatkan risiko cedera pada pergelangan tangan, bahu, dan punggung (Inotek, 2024).

Permasalahan utama yang sering terjadi adalah kurangnya pengawasan saat melakukan latihan secara mandiri. Latihan tanpa pengawasan pelatih profesional terbukti menghasilkan kualitas latihan yang tidak optimal. Ketiadaan supervisi dalam latihan kekuatan dilaporkan mengakibatkan kualitas latihan yang tidak memadai, sehingga performa yang dicapai lebih rendah dibandingkan latihan yang dilakukan dengan pengawasan (Fisher *et al.*, 2022). Tanpa umpan balik yang tepat, pengguna tidak dapat mengetahui apakah gerakan yang dilakukan sudah benar atau justru berpotensi menimbulkan cedera. Kondisi ini semakin diperparah dengan terbatasnya akses masyarakat terhadap pelatih olahraga profesional, terutama di era latihan mandiri yang semakin meningkat pasca pandemi COVID-19.

Perkembangan teknologi kecerdasan buatan, khususnya *deep learning* dan *computer vision*, membuka peluang besar untuk mengembangkan sistem evaluasi gerakan secara otomatis berbasis perangkat *mobile*. Sistem berbasis *AI* telah dikembangkan menggunakan model *pose estimation* untuk membantu pengguna

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

melacak latihan repetitif, mencatat riwayat olahraga, dan menilai performa guna mencegah cedera akibat bentuk gerakan yang tidak tepat (Zhang *et al.*, 2024). *Pose estimation* sendiri memiliki berbagai aplikasi dalam menganalisis gerakan dan perilaku tubuh manusia, termasuk memberikan umpan balik kepada pengguna tentang gerakan mereka sehingga mereka dapat menyesuaikan dan meningkatkan keterampilan gerakannya (Heliyon, 2024). Salah satu model *pose estimation* yang ringan dan cocok untuk perangkat *mobile* adalah *MoveNet* dari Google, yang mampu mendeteksi 17 *keypoint* tubuh secara *real-time*. Model *MoveNet* telah digunakan untuk mengevaluasi berbagai gerakan olahraga seperti *push-up*, *squat*, *jumping jacks*, dan *curls* dalam sistem kebugaran berbasis aplikasi dengan hasil yang menjanjikan (ICVIP, 2022).

Klasifikasi kualitas gerakan olahraga secara *real-time* dapat dilakukan dengan memanfaatkan koordinat *keypoint* tubuh sebagai *input* model *deep learning*, memungkinkan sistem untuk mengenali dan mengklasifikasikan gerakan olahraga secara langsung dari *feed* video tanpa memerlukan sensor tambahan (Moran *et al.*, 2022). Untuk mengklasifikasikan kualitas gerakan dari data sekuens *frame* video, diperlukan model *deep learning* yang mampu memproses data berurutan secara efektif. *Gated Recurrent Unit (GRU)* merupakan salah satu arsitektur *recurrent neural network* yang dirancang khusus untuk memproses data sekuens dengan kemampuan mengingat pola temporal antar *frame*. *GRU* telah terbukti efektif dalam mengklasifikasikan aktivitas manusia dengan performa tinggi, menjadikannya pilihan yang tepat untuk tugas pengenalan aksi berbasis sekuens video (Mohsen, 2023). Pengembangan model *Bidirectional Gated Recurrent Unit (BiGRU)* lebih lanjut meningkatkan kemampuan model dengan membaca sekuens data dari dua arah, yaitu maju dan mundur, sehingga konteks gerakan dapat dipahami secara lebih menyeluruh.

Berdasarkan permasalahan yang telah dipaparkan dan peluang penerapan teknologi yang ada, penelitian ini mengembangkan aplikasi *mobile* berbasis Android yang mampu mengevaluasi kualitas gerakan *push-up* secara *real-time* menggunakan model *BiGRU* dengan ekstraksi fitur berbasis *MoveNet*. Sistem 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

membantu pengguna melakukan latihan *push-up* secara mandiri dengan umpan balik otomatis yang akurat, sehingga manfaat latihan dapat dimaksimalkan sekaligus risiko cedera dapat diminimalkan.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, penelitian ini memfokuskan permasalahan pada tiga aspek utama sebagai berikut:

1. Bagaimana model *deep learning* dirancang dan dikembangkan dengan performa yang optimal untuk mengevaluasi kualitas gerakan *push-up*?
2. Bagaimana pengujian model *deep learning* dilakukan untuk mengevaluasi kualitas gerakan *push-up*?
3. Bagaimana model *deep learning* diimplementasikan dalam aplikasi *mobile* Android untuk membantu pengguna mengevaluasi gerakan *push-up* secara *real-time*?

1.3 Batasan Masalah

Agar penelitian ini tetap terfokus dan dapat diselesaikan sesuai ruang lingkup yang ditetapkan, berikut adalah batasan-batasan yang diterapkan dalam penelitian ini:

1. Data yang digunakan berupa video gerakan *push-up* sebanyak 220 video yang dikumpulkan secara mandiri.
2. Model dibuat hanya untuk klasifikasi gerakan *push-up* dengan dua kelas: benar dan salah.
3. Ekstraksi fitur dilakukan menggunakan model *MoveNet* yang menghasilkan 17 *keypoint* tubuh, dikombinasikan dengan fitur turunan sehingga menghasilkan 81 fitur per *frame*.
4. Arsitektur model yang digunakan adalah *Bidirectional Gated Recurrent Unit (BiGRU)* dengan *input* $30 \text{ frame} \times 81$ fitur per video.
5. Teknologi yang digunakan adalah *Python* dengan *library TensorFlow/Keras* untuk pelatihan model, dan *TensorFlow Lite* untuk *deployment* pada aplikasi Android.
6. Pengujian model menggunakan *evaluation metrics*: *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*.

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. Aplikasi *mobile* dikembangkan pada platform Android dengan inferensi *real-time* menggunakan kamera perangkat.

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan

Berdasarkan latar belakang dan rumusan masalah yang telah dijelaskan sebelumnya, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Mengembangkan model *deep learning BiGRU* yang mampu mengevaluasi kualitas gerakan *push-up* berdasarkan data video secara *real-time*.
2. Melakukan pengujian terhadap model *deep learning* yang telah dibuat untuk memastikan performa dan akurasi dalam mengevaluasi kualitas gerakan *push-up*.
3. Mengintegrasikan model *deep learning* ke dalam aplikasi *mobile* Android untuk mempermudah pengguna melakukan latihan mandiri.

1.4.2 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat bagi berbagai pihak, baik dari sisi pengguna maupun pengembangan ilmu pengetahuan. Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1. Membantu pengguna mengevaluasi kualitas gerakan *push-up* secara mandiri tanpa memerlukan pelatih profesional.
2. Mengurangi risiko cedera akibat kesalahan teknik *push-up* melalui umpan balik otomatis berbasis kecerdasan buatan.
3. Mendorong pengembangan teknologi kecerdasan buatan yang diterapkan dalam bidang kesehatan dan kebugaran.

1.5 Sistematika Penulisan

BAB I PENDAHULUAN

Berisi latar belakang masalah, rumusan masalah, batasan masalah, tujuan, manfaat, dan sistematika penulisan.

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

Berisi teori-teori yang mendukung penelitian dan ulasan penelitian terdahulu berdasarkan studi literatur.

BAB III METODE PENELITIAN

Menjelaskan rancangan penelitian, tahapan penelitian, objek penelitian, model/*framework*/teknik yang digunakan, teknik pengumpulan dan analisis data, jadwal pelaksanaan, dan rincian biaya.

BAB IV HASIL DAN PEMBAHASAN

Berisi realisasi rancangan penelitian, yaitu identifikasi kebutuhan, pembuatan model, pengujian, implementasi model ke aplikasi Android, dan analisis data yang didapat dari pengujian.

BAB V PENUTUP

Berisi kesimpulan penelitian dan saran untuk pengembangan lebih lanjut.

DAFTAR PUSTAKA



**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 Penelitian Terdahulu

Penelitian mengenai evaluasi gerakan olahraga berbasis *deep learning* dan *pose estimation* telah banyak dilakukan sebelumnya. Berikut adalah beberapa penelitian terdahulu yang relevan:

Penelitian yang dilakukan oleh Muzakir (2016) dengan judul "Rancang Bangun Aplikasi *Push-up Detector* untuk Mendeteksi Kesalahan Gerakan *Push-up*" menggunakan *computer vision* untuk mendeteksi pola gerakan *push-up* dan memberikan indikasi kesalahan. Namun, evaluasi yang dilakukan masih terbatas dan belum menggunakan pendekatan *deep learning* berbasis *time-series*.

Penelitian oleh Arlin & Munir (2023) dengan judul "Pengembangan Aplikasi Android untuk Analisis Gerakan *Push-up*" menggunakan *computer vision* untuk menghitung repetisi dan mendeteksi pola gerakan. Keterbatasan penelitian ini adalah evaluasi kualitas gerakan antar *frame* belum difokuskan.

Penelitian oleh Andriawan, Kasih, & Pamungkas (2025) dengan judul "Implementasi Teknik Ekstraksi *Pose* dengan *MediaPipe* dan Klasifikasi *Random Forest* untuk Penentuan Kualitas Gerakan *Push-Up*" menggunakan *MediaPipe Pose* untuk ekstraksi *keypoint* dan *Random Forest* untuk klasifikasi gerakan *push-up* benar/salah. Penelitian ini mencapai akurasi total 95% dengan sistem *GUI* berbasis *Tkinter*. Keterbatasannya adalah akurasi dapat menurun pada gerakan tidak konsisten, belum menggunakan model sekuensial, dan belum terintegrasi ke aplikasi *mobile*.

Penelitian oleh Citra *et al.* (2025) dengan judul "Analisis Sistem Deteksi Gerakan *Push-up* Berbasis *MediaPipe*" menggunakan *MediaPipe Pose* untuk estimasi 33 titik sendi dan menghitung sudut siku serta pinggul secara *real-time*. Sistem mampu mendeteksi jumlah *push-up*, tahap gerakan (*up/down*), dan estimasi kalori. Keterbatasannya adalah akurasi menurun pada pencahayaan buruk dan sistem belum memberikan umpan balik korektif yang spesifik.

Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa pendekatan berbasis *pose estimation* terbukti efektif untuk analisis gerakan *push-up*. Penelitian ini mengembangkan lebih lanjut dengan menggunakan model *Bidirectional Gated Recurrent Unit (BiGRU)* yang membaca sekuens *frame* dari dua arah, dikombinasikan dengan 81 fitur per *frame*, dan diintegrasikan ke dalam aplikasi Android secara *real-time*.

Tabel 2. 1 Perbandingan Penelitian Terdahulu

NO	Penelitian	Hasil	Kekurangan
1	(Muzakir, 2016) – Rancang Bangun Aplikasi Push-up Detector untuk Mendeteksi Kesalahan Gerakan Push-up	Menggunakan computer vision untuk mendeteksi pola gerakan push-up. Sistem mampu mengenali pola gerakan dan memberikan indikasi kesalahan.	Evaluasi terbatas; belum menggunakan deep learning berbasis time-series.
2	(Arlin & Munir, 2023) – Pengembangan Aplikasi Android untuk Analisis Gerakan Push-up	Menggunakan computer vision untuk menghitung repetisi dan pola gerakan. Dapat mendeteksi jumlah repetisi dan pola gerakan.	Evaluasi kualitas gerakan antar frame belum difokuskan.
3	Andriawan, R., Kasih, P., & Pamungkas, D. P. (2025) – Implementasi Teknik Ekstraksi Pose dengan MediaPipe dan Klasifikasi Random Forest untuk	Menggunakan MediaPipe Pose untuk ekstraksi keypoints dan Random Forest untuk klasifikasi gerakan push-up benar/salah. Akurasi total 95% dengan performa baik pada majority voting per frame. Sistem	Akurasi dapat menurun pada gerakan tidak konsisten. Sistem belum menggunakan model sekuensial (GRU/LSTM) dan belum terintegrasi ke aplikasi mobile.

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

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

	Penentuan Kualitas Gerakan Push-Up	memiliki GUI berbasis Tkinter untuk upload video dan melihat hasil klasifikasi.
4	Citra, P., Latihan Sistem Mandiri, P., Suraju, G., Sahertian, J., & Irawan, R. H. (2025) – Analisis Sistem Deteksi Gerakan Push-up Berbasis MediaPipe	menggunakan Akurasi Pose untuk estimasi 33 titik sendi dan menghitung sudut siku & pinggul secara real-time. Mampu mendeteksi Sistem belum jumlah push-up, tahap memberikan umpan gerakan (up/down), dan balik korektif spesifik estimasi kalori (misal 8 push-up = 87.43 Kcal). (misal instruksi "luruskan punggung").

2.2 Push-Up

Push-up adalah salah satu latihan fisik *bodyweight* yang paling umum dilakukan karena tidak memerlukan peralatan khusus dan dapat dilakukan di mana saja. Gerakan *push-up* melibatkan berbagai kelompok otot utama, termasuk otot dada (*pectoralis major*), trisep, bahu (*deltoid*), dan otot inti (*core*), sehingga efektif untuk meningkatkan kekuatan dan daya tahan tubuh bagian atas secara menyeluruh. Menurut Winarno (2018), gerakan *push-up* yang benar dilakukan dengan menjaga posisi tubuh tetap lurus dari kepala hingga tumit, tangan diletakkan sejajar bahu, siku membentuk sudut sekitar 90 derajat saat menekuk, serta dada mendekati lantai tanpa menyentuh. Gerakan dilakukan dengan kontrol penuh, tidak terlalu cepat maupun terlalu lambat. Ilustrasi gerakan *push-up* yang benar ditunjukkan pada Gambar 2.1.


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 2. 1 Push Up Benar

Sumber: https://youtube.com/shorts/whG_uV6SEbY?si=HfdzmIRHs5VgMRV9

Kesalahan yang paling sering terjadi saat *push-up* antara lain adalah posisi pinggang yang terlalu melengkung ke atas atau ke bawah, siku yang terlalu melebar ke samping, kepala yang mendongak, serta gerakan yang terlalu cepat sehingga tidak terkontrol. Kesalahan-kesalahan ini dapat mengurangi efektivitas latihan dan meningkatkan risiko cedera pada bahu, pergelangan tangan, dan punggung bagian bawah (Inotek, 2024). Ilustrasi beberapa kesalahan dalam melakukan gerakan *push-up* ditunjukkan pada Gambar 2.2.



Gambar 2. 2 Push Up Salah

Sumber: <https://vt.tiktok.com/ZSCn8y4F8/>

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

2.3 Pose Estimation

Pose estimation adalah teknik computer vision yang bertujuan untuk mendeteksi dan melacak posisi serta orientasi tubuh manusia dari gambar atau video. Teknologi ini bekerja dengan mengidentifikasi titik-titik penting pada tubuh manusia yang disebut keypoint, seperti sendi bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki (Heliyon, 2024).

2.3.1 Microsoft COCO dan Standar 17 Keypoint

Microsoft COCO (Common Objects in Context) mendefinisikan standar 17 keypoint untuk tubuh manusia yang telah menjadi acuan utama dalam pengembangan model pose estimation modern. Dataset ini memuat lebih dari 200.000 gambar dengan 250.000 anotasi keypoint dan menjadi benchmark utama dalam evaluasi model pose estimation (Lin et al., 2014). Ke-17 keypoint tersebut mencakup:

Tabel 2. 2 Daftar 17 Keypoint

No	Keypoint	Bagian Tubuh
0	Hidung	Kepala
1	Mata Kiri	Kepala
2	Mata Kanan	Kepala
3	Telinga Kiri	Kepala
4	Telinga Kanan	Kepala
5	Bahu Kiri	Tubuh Atas
6	Bahu Kanan	Tubuh Atas
7	Siku Kiri	Tubuh Atas
8	Siku Kanan	Tubuh Atas
9	Pergelangan Tangan Kiri	Tubuh Atas
10	Pergelangan Tangan Kanan	Tubuh Atas
11	Pinggul Kiri	Tubuh Bawah
12	Pinggul Kanan	Tubuh Bawah

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

No	Keypoint	Bagian Tubuh
13	Lutut Kiri	Tubuh Bawah
14	Lutut Kanan	Tubuh Bawah
15	Pergelangan Kaki Kiri	Tubuh Bawah
16	Pergelangan Kaki Kanan	Tubuh Bawah

2.3.2 MoveNet

MoveNet merupakan model *pose estimation* yang dikembangkan oleh Google dan dioptimalkan untuk bekerja secara *real-time* pada perangkat bergerak (*mobile devices*). Model ini tersedia dalam dua varian, yaitu *MoveNet Lightning* yang memiliki ukuran lebih ringan dengan kecepatan inferensi yang tinggi, serta *MoveNet Thunder* yang menawarkan tingkat akurasi lebih baik dengan kebutuhan sumber daya komputasi yang lebih besar.



Gambar 2. 3 Visualisasi 17 Keypoint pada Tubuh Manusia

Sumber: <https://www.tensorflow.org/hub/tutorials/movenet>

MoveNet merupakan model *pose estimation* yang dikembangkan oleh Google dan tersedia dalam dua varian, yaitu *Lightning* yang dioptimalkan untuk kecepatan inferensi serta *Thunder* yang menawarkan akurasi lebih tinggi dengan kebutuhan komputasi yang lebih besar. Berdasarkan dokumentasi resmi TensorFlow, *MoveNet* menghasilkan keluaran berupa 17 *keypoint* tubuh manusia yang masing-masing

terdiri atas koordinat (x, y) dan *confidence score*, serta mengikuti standar *Microsoft Common Objects in Context (MS COCO)*. Model ini juga dirancang untuk mendukung inferensi secara *real-time* pada berbagai perangkat, termasuk perangkat bergerak (*mobile*) dan *edge devices* (TensorFlow, 2024). *MoveNet* mampu mendeteksi 17 *keypoint* tubuh manusia berdasarkan standar *Microsoft Common Objects in Context (MS COCO)* dengan latensi kurang dari 10 milidetik pada perangkat *mobile* modern (ICVIP, 2022). Setiap *keypoint* yang terdeteksi direpresentasikan dalam bentuk koordinat (x, y) serta *confidence score* yang menunjukkan tingkat keyakinan model terhadap hasil deteksi pada titik tersebut (Jo & Kim, 2022). Selanjutnya, keluaran (*output*) tersebut telah divalidasi dan dapat dimanfaatkan sebagai dasar dalam perhitungan sudut sendi maupun ekstraksi berbagai fitur biomekanik turunan untuk analisis gerakan manusia (Alvarez, 2023).

2.4 Deep Learning

Deep learning merupakan salah satu cabang dari *machine learning* yang menggunakan arsitektur *neural network* berlapis untuk mengekstraksi fitur secara otomatis dari data mentah. *Deep learning* sangat efektif untuk tugas-tugas yang melibatkan data berdimensi tinggi seperti gambar, video, audio, dan data sekuens temporal (Mohsen, 2023).

2.4.1 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) adalah arsitektur *neural network* yang dirancang khusus untuk memproses data berurutan (*sequential data*). Berbeda dengan *neural network* konvensional yang memproses setiap input secara independen, RNN memiliki memori internal yang memungkinkan informasi dari *input* sebelumnya dipertahankan dan digunakan untuk memproses *input* berikutnya. Kemampuan ini menjadikan RNN sangat cocok untuk data yang memiliki ketergantungan temporal, seperti urutan *frame* video (Moran et al., 2022).

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

2.4.2 Gated Recurrent Unit (GRU)

GRU memiliki struktur yang lebih sederhana dibandingkan *Long Short-Term Memory* (LSTM), namun tetap mampu mempertahankan informasi penting dari data sekuens melalui mekanisme dua *gate*. Arsitektur *GRU* terdiri atas dua komponen utama, yaitu *reset gate* dan *update gate*, yang bekerja sama dalam mengatur aliran informasi selama proses pembelajaran. Kedua *gate* tersebut memungkinkan model menentukan informasi yang perlu dipertahankan maupun diperbarui berdasarkan masukan yang diterima pada setiap langkah waktu. Dengan mekanisme tersebut, *GRU* mampu mempelajari hubungan temporal secara efisien tanpa memerlukan struktur yang terlalu kompleks. Arsitektur *Gated Recurrent Unit* (*GRU*) yang terdiri atas *reset gate* dan *update gate* ditunjukkan pada Gambar 2.4.



Gambar 2. 4 Arsitektur GRU dengan reset gate dan update gate

Sumber: <https://towardsdatascience.com/gru-recurrent-neural-networks-a-smart-way-to-predict-sequences-in-python-80864e4fe9f6/>

Berdasarkan Gambar 2.4, proses pada *GRU* diawali dengan masukan (*input*) x_t dan *hidden state* sebelumnya (h_{t-1}). Kedua informasi tersebut digunakan untuk menghitung nilai *reset gate* dan *update gate*. *Reset gate* berfungsi mengatur seberapa besar informasi dari *hidden state* sebelumnya digunakan dalam pembentukan *candidate hidden state* melalui fungsi aktivasi *tanh*. Selanjutnya, *update gate* menentukan proporsi antara informasi lama dari *hidden state*

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

sebelumnya dan informasi baru dari *candidate hidden state* untuk menghasilkan *hidden state* baru (h_t). Mekanisme ini memungkinkan *GRU* mempertahankan informasi yang masih relevan sekaligus memperbarui memori dengan informasi baru secara efisien.

2.4.3 Bidirectional GRU (*BiGRU*)

Bidirectional Gated Recurrent Unit (BiGRU) merupakan pengembangan dari *Gated Recurrent Unit (GRU)* yang memproses data sekuens dari dua arah secara bersamaan, yaitu arah maju (*forward*) dari *frame* pertama menuju *frame* terakhir dan arah mundur (*backward*) dari *frame* terakhir menuju *frame* pertama. Berbeda dengan *GRU* konvensional yang hanya memanfaatkan informasi dari urutan sebelumnya, *BiGRU* mampu mempelajari hubungan antar data dari masa lalu maupun masa depan sehingga menghasilkan representasi sekuens yang lebih lengkap (Moran *et al.*, 2022). Kemampuan tersebut sangat bermanfaat pada tugas klasifikasi gerakan karena setiap *frame* tidak hanya dipengaruhi oleh posisi sebelumnya, tetapi juga oleh pola gerakan yang terjadi setelahnya. Keunggulan tersebut menjadikan *BiGRU* banyak digunakan pada berbagai tugas klasifikasi berbasis data sekuens, termasuk pengenalan aktivitas manusia dan analisis gerakan olahraga. Kemampuan memproses informasi dari dua arah memungkinkan model menghasilkan representasi fitur yang lebih kaya dibandingkan model sekuens satu arah. Arsitektur *Bidirectional Gated Recurrent Unit (BiGRU)* yang menerapkan mekanisme pemrosesan dua arah tersebut ditunjukkan pada Gambar 2.5.



Gambar 2. 5 Arsitektur Bidirectional Gated Recurrent Unit (*BiGRU*)

Sumber : <https://www.researchgate.net/journal/Mathematics-2227-7390>

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

Berdasarkan Gambar 2.5, data masukan (*input sequence*) terlebih dahulu diproses secara paralel melalui dua lapisan *GRU* yang berbeda, yaitu *Forward GRU* dan *Backward GRU*. Jalur *Forward GRU* memproses data secara berurutan mulai dari waktu t_1 hingga t_n , sehingga setiap keluaran dipengaruhi oleh informasi pada *frame-frame* sebelumnya. Sebaliknya, *Backward GRU* memproses data dari waktu t_n menuju t_1 , sehingga setiap keluaran juga mempertimbangkan informasi dari *frame-frame* berikutnya. Hasil keluaran dari kedua jalur tersebut kemudian digabungkan (*concatenate*) untuk membentuk representasi fitur yang lebih kaya sebelum diteruskan ke *output layer*. Menurut Mahdi *et al.* (2025), mekanisme dua arah ini memungkinkan model menangkap ketergantungan jangka pendek maupun jangka panjang secara lebih efektif dibandingkan model sekuens satu arah, sehingga mampu menghasilkan representasi data yang lebih komprehensif untuk proses prediksi maupun klasifikasi.

BiGRU digunakan dalam penelitian ini untuk mempelajari urutan fitur hasil ekstraksi *pose* pada setiap *frame* gerakan *push-up*. Proses *forward* mempelajari perubahan gerakan dari posisi awal hingga posisi akhir, sedangkan proses *backward* memanfaatkan informasi dari posisi akhir menuju posisi awal. Kombinasi kedua arah tersebut memungkinkan model memahami hubungan antar *frame* secara lebih menyeluruh sehingga pola gerakan yang benar maupun yang kurang tepat dapat dibedakan dengan lebih akurat. Kemampuan tersebut menjadikan *BiGRU* sesuai untuk mengolah data gerakan yang memiliki karakteristik temporal dan saling bergantung antar *frame*. Penerapan *BiGRU* diharapkan mampu meningkatkan performa model dalam mengevaluasi kualitas gerakan *push-up* berdasarkan urutan gerakan yang dilakukan pengguna.

2.5 Feature Engineering

Feature engineering merupakan proses mengubah data mentah menjadi fitur numerik yang lebih informatif dan relevan sehingga dapat meningkatkan kinerja model *machine learning*. Penelitian ini menerapkan *feature engineering* terhadap hasil deteksi *pose* dari *MoveNet Thunder* untuk membentuk representasi fitur yang

mampu menggambarkan karakteristik gerakan *push-up* secara lebih komprehensif. Setiap *frame* yang diproses menghasilkan 17 *keypoint* tubuh berupa koordinat (x , y) dan *confidence score* yang menjadi dasar dalam pembentukan fitur (Alvarez, 2023). Proses tersebut bertujuan menghasilkan representasi data yang tidak hanya memuat informasi posisi tubuh, tetapi juga hubungan antarbagian tubuh selama melakukan gerakan. Representasi fitur yang lebih kaya diharapkan mampu meningkatkan kemampuan model dalam membedakan gerakan *push-up* yang benar dan salah.

Berdasarkan *keypoint* tersebut, dilakukan ekstraksi berbagai fitur tambahan yang merepresentasikan aspek spasial, biomekanik, dan temporal gerakan. Sebanyak 34 koordinat (x , y) dan 17 *confidence score* digunakan sebagai fitur dasar. Selanjutnya ditambahkan 10 sudut biomekanik pada sendi siku, bahu, pinggul, dan lutut yang dihitung menggunakan metode *joint angle* dari tiga titik *keypoint* (Alvarez, 2023; Hamilton *et al.*, 2024).

Untuk mengatasi *keypoint* tubuh bagian bawah yang tidak terdeteksi, ditambahkan enam *missing flags* dengan pendekatan *FERA* yang merepresentasikan *keypoint* hilang sebagai nilai nol (Chen & Wang, 2025). Selain itu, informasi temporal diperoleh melalui perhitungan *velocity* pada 12 *keypoint* antar *frame* menggunakan pendekatan *Joint Velocity Transform Module* yang terbukti meningkatkan akurasi pengenalan gerakan (Guan *et al.*, 2022). Dua fitur tambahan berupa rasio panjang segmen tubuh dan selisih tinggi siku kiri-kanan juga digunakan untuk merepresentasikan karakteristik khusus gerakan *push-up* berdasarkan konsep analisis simetri bilateral (Jo & Kim, 2022). Pendekatan pembentukan *multidimensional feature vector* seperti ini telah banyak diterapkan pada klasifikasi gerakan olahraga, sebagaimana dilakukan oleh Riccio (2024) dan IJERT (2026).

Kombinasi seluruh fitur tersebut menghasilkan vektor berdimensi 81 pada setiap *frame*. Vektor tersebut memuat informasi posisi, tingkat kepercayaan deteksi, karakteristik biomekanik, serta perubahan gerakan antar *frame* sehingga mampu merepresentasikan pola gerakan secara lebih lengkap. Representasi fitur 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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

komprehensif tersebut menjadi masukan bagi model *Bidirectional Gated Recurrent Unit (BiGRU)* untuk mempelajari pola gerakan *push-up* secara temporal. Rincian kelompok fitur yang digunakan dalam penelitian ini disajikan pada Tabel 2.3.

Tabel 2. 3 Deskripsi 81 Fitur per Frame

No.	Kelompok Fitur	Jumlah	Indeks	Keterangan
1	Koordinat (x, y)	34	0–33	Posisi 17 keypoint pada bidang citra
2	Sudut biomekanik	10	34–43	Sudut pada sendi siku, bahu, pinggul, dan lutut
3	Confidence score	17	44–60	Tingkat keyakinan model terhadap setiap keypoint
4	Missing flags	6	61–66	Penanda keypoint lower body yang tidak terdeteksi
5	Velocity	12	67–78	Kecepatan perpindahan keypoint antar-frame
6	Fitur khusus push-up	2	79–80	Rasio segmen tubuh dan indikator simetri siku
	Total	81	0–80	81 fitur kontigu tanpa celah

Berdasarkan Tabel 2.3, fitur-fitur yang digunakan mampu merepresentasikan gerakan *push-up* secara komprehensif. Seluruh 17 *keypoint* yang dihasilkan oleh *MoveNet* digunakan tanpa proses seleksi, termasuk *keypoint* pada area wajah seperti hidung, mata, dan telinga. Pendekatan ini mengacu pada konsep *multidimensional feature vector* yang diterapkan oleh Riccio (2024) dan IJERT (2026), yaitu memanfaatkan seluruh *landmark pose* tanpa proses penyaringan karena setiap *keypoint* tetap memberikan informasi mengenai posisi tubuh maupun kualitas deteksi yang dapat dimanfaatkan oleh model *deep learning* untuk mempelajari pola gerakan secara lebih optimal. Koordinat *keypoint* merepresentasikan posisi spasial tubuh, sedangkan sudut biomekanik menggambarkan postur dan keselarasan

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

antarsegmen tubuh selama gerakan. *Confidence score* digunakan untuk menunjukkan tingkat keyakinan hasil deteksi *MoveNet*, sementara *missing flags* mengidentifikasi kondisi ketika *keypoint* tubuh bagian bawah tidak berhasil terdeteksi. Informasi temporal direpresentasikan melalui fitur *velocity* yang menggambarkan perubahan posisi *keypoint* antar *frame*, sedangkan dua fitur khusus *push-up* berupa rasio segmen tubuh dan selisih tinggi siku kiri-kanan digunakan untuk menangkap karakteristik postur gerakan. Dengan demikian, seluruh fitur tersusun secara berurutan pada indeks 0–80 tanpa adanya *gap*, sehingga memudahkan proses standardisasi data serta pelatihan model *deep learning*.

2.6 Stratified Split (Pembagian Data Bertingkat)

Stratified split merupakan teknik pembagian dataset yang mempertahankan proporsi setiap kelas atau strata pada setiap subset data sehingga distribusi data pelatihan, data validasi, dan data pengujian tetap representatif. Teknik ini dilakukan dengan menjaga persentase sampel dari tiap kelas pada label *y* saat proses pembagian data berlangsung (StratifiedShuffleSplit, dokumentasi scikit-learn, 2026). Teknik ini banyak digunakan pada permasalahan klasifikasi untuk mengurangi kemungkinan ketidakseimbangan distribusi data akibat proses pembagian secara acak (random split).

Untuk menentukan rasio pembagian dataset yang sesuai, dilakukan analisis terhadap beberapa konfigurasi pembagian data menggunakan metode StratifiedShuffleSplit. Metode ini merupakan gabungan antara StratifiedKFold dan ShuffleSplit yang menghasilkan pembagian acak sekaligus tetap mempertahankan proporsi kelas pada setiap subset (StratifiedShuffleSplit, dokumentasi scikit-learn, 2026). Setiap konfigurasi dievaluasi secara berulang menggunakan random seed yang berbeda untuk mengurangi pengaruh variasi akibat proses pembagian data secara acak sehingga hasil evaluasi menjadi lebih stabil. Pendekatan ini penting dilakukan karena variasi seed pada proses pembagian data terbukti dapat menghasilkan perbedaan performa model yang signifikan secara statistik, terutama pada metode split-sample validation dengan ukuran dataset yang relatif kecil (Singh 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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hasil analisis terhadap sembilan konfigurasi rasio pembagian dataset disajikan pada Tabel 2.5.

Tabel 2. 4 Analisis Sembilan Konfigurasi Rasio Split

Konfigurasi	n Train	n Val	n Test	Min Strata (Test/Val)	Status
60/20/20	132	44	44	7,0 / 7,5	Memenuhi
65/20/15	143	44	33	6,0 / 7,0	Memenuhi
70/15/15	154	33	33	6,0 / 6,0	Memenuhi
70/20/10	154	44	22	4,0 / 7,5	Tidak Memenuhi
70/10/20	154	22	44	7,0 / 4,0	Tidak Memenuhi
75/15/10	165	33	22	4,0 / 6,0	Tidak Memenuhi
80/10/10	176	22	22	4,0 / 4,0	Tidak Memenuhi
85/10/05	187	22	11	2,0 / 4,0	Tidak Memenuhi
90/05/05	198	11	11	2,0 / 2,0	Tidak Memenuh

Berdasarkan Tabel 2.5, konfigurasi 60/20/20, 65/20/15, dan 70/15/15 memenuhi kriteria karena mampu menyediakan jumlah sampel yang memadai pada setiap

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

subset data. Konfigurasi lainnya memiliki jumlah sampel yang terlalu sedikit pada data validasi atau data pengujian sehingga kurang ideal untuk proses evaluasi model, karena split-sample validation dengan ukuran subset kecil terbukti menghasilkan rentang estimasi performa yang jauh lebih tidak stabil dibandingkan metode yang lebih robust (Singh et al., 2021). Rasio 70% data pelatihan, 15% data validasi, dan 15% data pengujian dipilih karena memberikan jumlah data pelatihan yang lebih besar tanpa mengurangi representasi data pada proses validasi maupun pengujian. Pemilihan rasio tersebut diharapkan mampu menghasilkan proses pelatihan yang optimal sekaligus memberikan evaluasi model yang lebih andal.

2.7 Augmentasi Data

Augmentasi data merupakan teknik untuk memperbanyak jumlah data latih secara artifisial dengan membuat variasi dari data yang sudah ada tanpa mengubah label maupun makna data tersebut. Teknik ini banyak digunakan pada penelitian *machine learning* dan *deep learning* ketika jumlah data terbatas karena mampu meningkatkan keragaman data latih sehingga model lebih mampu melakukan generalisasi terhadap data baru (Zhang et al., 2024). Selain meningkatkan keragaman data, *augmentasi data* juga dapat membantu mengurangi risiko *overfitting* karena model dilatih menggunakan variasi data yang lebih beragam. Penerapan *augmentasi data* umumnya hanya dilakukan pada data pelatihan (*training data*), sedangkan data validasi (*validation data*) dan data pengujian (*testing data*) tetap dipertahankan dalam kondisi asli agar proses evaluasi model berlangsung secara objektif. Dengan demikian, performa model yang diperoleh mencerminkan kemampuan model dalam mengenali data yang belum pernah dilihat sebelumnya.

Penelitian ini menerapkan *augmentasi data* sebanyak tiga variasi pada setiap data pelatihan. Variasi pertama menggunakan data asli tanpa modifikasi sebagai representasi kondisi awal data. Variasi kedua menambahkan *noise* berupa gangguan acak bernilai kecil pada koordinat *keypoint* untuk mensimulasikan ketidaksempurnaan proses deteksi *pose* pada kondisi nyata. Variasi ketiga menerapkan *scale* pada koordinat *keypoint* untuk mensimulasikan perubahan jarak

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

antara kamera dan subjek. Ketiga variasi tersebut bertujuan meningkatkan keragaman data pelatihan sehingga model mampu mempelajari pola gerakan *push-up* dengan lebih baik dan memiliki kemampuan generalisasi yang lebih tinggi

2.8 Batch Normalization

Batch Normalization merupakan teknik yang digunakan untuk menstabilkan dan mempercepat proses pelatihan model *deep learning* dengan cara menormalisasi nilai keluaran (*output*) dari setiap lapisan sebelum diteruskan ke lapisan berikutnya. Secara umum, *Batch Normalization* memastikan bahwa nilai *output* memiliki rata-rata mendekati 0 dan standar deviasi mendekati 1 pada setiap *mini-batch* selama proses *training*. Teknik ini membantu mengatasi masalah *internal covariate shift*, yaitu perubahan distribusi nilai masukan pada setiap lapisan yang dapat memperlambat proses konvergensi model dan menyebabkan pelatihan menjadi kurang stabil (Mohsen, 2023). Selain meningkatkan stabilitas pelatihan, *Batch Normalization* juga memungkinkan penggunaan *learning rate* yang lebih tinggi tanpa mengurangi performa model. Oleh karena itu, teknik ini banyak diterapkan pada berbagai arsitektur *deep learning* untuk meningkatkan efisiensi dan keandalan proses pelatihan.

Penelitian ini menerapkan *Batch Normalization* setelah setiap lapisan *Bidirectional Gated Recurrent Unit (BiGRU)* sebelum data diteruskan ke lapisan *Dropout* dan lapisan berikutnya. Penempatan tersebut bertujuan menstabilkan distribusi nilai *output* yang dihasilkan oleh setiap lapisan sehingga proses pembelajaran berlangsung secara lebih konsisten. Distribusi data yang lebih stabil membantu mempercepat proses konvergensi selama *training* sekaligus meningkatkan efektivitas proses pembelajaran model. Penerapan *Batch Normalization* juga membantu mengurangi fluktuasi nilai selama pelatihan sehingga model menjadi lebih stabil. Dengan demikian, model diharapkan mampu mencapai performa yang optimal dalam jumlah *epoch* yang lebih sedikit.

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

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

2.9 Label Smoothing

Label Smoothing merupakan teknik regularisasi yang digunakan untuk mencegah model menjadi terlalu percaya diri (*overconfident*) terhadap hasil prediksinya. Teknik ini bekerja dengan mengubah *hard label* yang bernilai 0 atau 1 menjadi *soft label* yang nilainya sedikit mendekati nilai tengah. Sebagai contoh, dengan nilai *label smoothing* sebesar 0,05, label positif dapat direpresentasikan menjadi sekitar 0,95, sedangkan label negatif menjadi sekitar 0,05. Pendekatan tersebut membantu model mengurangi kecenderungan menghafal data pelatihan (*training data*) serta menghasilkan probabilitas prediksi yang lebih terkalibrasi (Zhang *et al.*, 2024). Selain meningkatkan kemampuan generalisasi, *Label Smoothing* juga dapat membantu mengurangi risiko *overfitting* pada proses pelatihan model.

Penelitian ini menerapkan *Label Smoothing* dengan nilai 0,05 pada fungsi *Binary Crossentropy* selama proses pelatihan model. Penerapan teknik tersebut bertujuan mengurangi kecenderungan model menghasilkan prediksi dengan tingkat keyakinan yang terlalu tinggi terhadap data pelatihan. Probabilitas prediksi yang lebih terkalibrasi diharapkan mampu meningkatkan kemampuan model dalam mengenali data baru yang belum pernah dilihat sebelumnya. Selain itu, *Label Smoothing* membantu proses pelatihan menjadi lebih stabil dengan mengurangi risiko model terlalu menyesuaikan diri terhadap data pelatihan. Dengan demikian, model diharapkan memiliki kemampuan generalisasi yang lebih baik ketika digunakan untuk mengevaluasi kualitas gerakan *push-up*.

2.10 Early Stopping

Early Stopping merupakan teknik regularisasi yang digunakan untuk menghentikan proses pelatihan model secara otomatis ketika performa model pada data validasi tidak lagi menunjukkan peningkatan yang signifikan selama sejumlah *epoch* tertentu. Teknik ini bertujuan mencegah *overfitting*, yaitu kondisi ketika model terlalu menyesuaikan diri terhadap data pelatihan sehingga performanya menurun saat dihadapkan pada data baru (Mohsen, 2023). Dengan menghentikan pelatihan pada waktu yang tepat, *Early Stopping* membantu model memperoleh kemampuan generalisasi yang lebih baik. Selain itu, teknik ini juga mengurangi waktu

komputasi karena proses pelatihan tidak dilanjutkan ketika peningkatan performa sudah tidak signifikan. Oleh karena itu, *Early Stopping* menjadi salah satu teknik yang umum digunakan dalam pelatihan model *deep learning*.

Early Stopping dikendalikan oleh parameter *patience*, yaitu jumlah *epoch* yang tetap dijalankan meskipun tidak terjadi peningkatan performa pada data validasi. Apabila performa model tidak mengalami peningkatan selama jumlah *epoch* yang ditentukan oleh nilai *patience*, proses pelatihan akan dihentikan secara otomatis. Mekanisme tersebut membantu memperoleh model dengan performa terbaik tanpa perlu menyelesaikan seluruh *epoch* yang telah ditentukan. Penelitian ini menerapkan *Early Stopping* untuk mengendalikan proses pelatihan agar model tidak mengalami *overfitting* dan mampu mempertahankan kemampuan generalisasi terhadap data baru. Dengan demikian, model diharapkan mencapai performa yang optimal tanpa melakukan pelatihan secara berlebihan.

2.11 Normalisasi Data

Normalisasi data merupakan proses transformasi nilai fitur agar memiliki skala yang seragam sehingga dapat meningkatkan stabilitas numerik dan efisiensi selama proses pelatihan model *deep learning*. Tahap ini bertujuan mengurangi pengaruh perbedaan skala antar fitur sehingga setiap fitur memberikan kontribusi yang lebih seimbang dalam proses pembelajaran model serta mempercepat proses konvergensi selama pelatihan (Mohsen, 2023). Selain meningkatkan stabilitas pelatihan, normalisasi data juga membantu mengurangi dominasi fitur yang memiliki rentang nilai lebih besar dibandingkan fitur lainnya. Oleh karena itu, proses normalisasi menjadi salah satu tahap penting dalam *preprocessing* data sebelum model dilatih. Berbagai metode normalisasi telah dikembangkan, salah satunya adalah *Z-Score Standardization*.

Penelitian ini menggunakan metode *Z-Score Standardization* yang diimplementasikan melalui *StandardScaler* dari *library scikit-learn*. Metode ini mengubah setiap nilai fitur berdasarkan nilai rata-rata (*mean*) dan simpangan baku (*standard deviation*) sehingga data hasil transformasi memiliki rata-rata mendekati

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

0 dan simpangan baku mendekati 1. Persamaan *Z-Score Standardization* ditunjukkan pada Persamaan (2.X).

$$X' = \frac{X - \mu}{\sigma}$$

Keterangan:

- X = nilai fitur sebelum proses standardisasi.
- X' = nilai fitur setelah proses standardisasi.
- μ = nilai rata-rata (*mean*) dari seluruh data fitur.
- σ = simpangan baku (*standard deviation*) dari seluruh data fitur.

Metode *Z-Score Standardization* dipilih karena mampu menangani perbedaan distribusi antar fitur secara lebih efektif dibandingkan normalisasi berbasis rentang nilai. Seluruh fitur hasil ekstraksi *keypoint* distandardisasi sebelum digunakan sebagai masukan bagi model *Bidirectional Gated Recurrent Unit (BiGRU)*. Proses tersebut menghasilkan distribusi data yang lebih seragam sehingga membantu meningkatkan stabilitas proses pelatihan dan mempercepat konvergensi model. Selain itu, standardisasi juga mengurangi dominasi fitur dengan rentang nilai yang lebih besar sehingga setiap fitur dapat memberikan kontribusi yang lebih proporsional dalam proses klasifikasi. Dengan demikian, model diharapkan mampu mempelajari pola gerakan *push-up* secara lebih efektif dan menghasilkan performa klasifikasi yang lebih baik.

2.12 Evaluasi Model

Evaluasi model merupakan tahapan penting dalam pengembangan sistem *deep learning* untuk mengukur sejauh mana model yang telah dilatih mampu memberikan prediksi yang akurat terhadap data yang belum pernah dilihat sebelumnya. Proses evaluasi bertujuan mengetahui kemampuan model dalam melakukan klasifikasi sekaligus menilai kemampuan generalisasi terhadap data baru. Tanpa proses evaluasi yang tepat, tidak dapat dipastikan apakah model benar-benar mempelajari pola dari data atau hanya menghafal data pelatihan (*overfitting*).

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

Hasil evaluasi juga menjadi dasar dalam membandingkan performa beberapa model maupun konfigurasi yang berbeda sehingga model terbaik dapat dipilih secara objektif. Oleh karena itu, penggunaan metrik evaluasi yang sesuai sangat diperlukan untuk memberikan gambaran menyeluruh mengenai kualitas model. Penelitian ini menggunakan beberapa metrik evaluasi yang umum diterapkan pada permasalahan klasifikasi biner, yaitu *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, dan *Receiver Operating Characteristic–Area Under the Curve (ROC-AUC)*.

2.12.1 Confusion Matrix

Confusion matrix adalah tabel yang digunakan untuk mengevaluasi performa model klasifikasi dengan membandingkan hasil prediksi model terhadap nilai sebenarnya secara menyeluruh. *Confusion matrix* memberikan gambaran yang lebih lengkap dibandingkan hanya menggunakan *accuracy* karena mampu menunjukkan jenis kesalahan yang dilakukan oleh model secara spesifik. Informasi tersebut membantu dalam menganalisis kemampuan model dalam mengklasifikasikan setiap kelas serta mengidentifikasi kesalahan prediksi yang masih terjadi (Mohsen, 2023). Pada permasalahan klasifikasi biner, *confusion matrix* terdiri atas empat komponen utama, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Bentuk *confusion matrix* pada klasifikasi biner ditunjukkan pada Tabel 2.6.

Tabel 2. 5 Confusion Matrix

Kondisi Sebenarnya	Prediksi Salah	Prediksi Benar
Salah	TN	FP
Benar	FN	TP

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 Tabel 2.6, setiap komponen pada *confusion matrix* memiliki makna sebagai berikut:

- *True Positive* (TP) merupakan kondisi ketika data yang sebenarnya termasuk gerakan *push-up* benar berhasil diprediksi benar oleh model.
- *True Negative* (TN) merupakan kondisi ketika data yang sebenarnya termasuk gerakan *push-up* salah berhasil diprediksi salah oleh model.
- *False Positive* (FP) merupakan kondisi ketika data yang sebenarnya termasuk gerakan *push-up* salah, tetapi diprediksi sebagai gerakan benar oleh model (*false alarm*).
- *False Negative* (FN) merupakan kondisi ketika data yang sebenarnya termasuk gerakan *push-up* benar, tetapi diprediksi sebagai gerakan salah oleh model (*miss*).

Keempat komponen tersebut menjadi dasar dalam perhitungan berbagai metrik evaluasi, seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Oleh karena itu, *confusion matrix* tidak hanya digunakan untuk mengetahui jumlah prediksi yang benar, tetapi juga untuk menganalisis jenis kesalahan yang dilakukan oleh model sehingga performanya dapat dievaluasi secara lebih komprehensif.

2.12.2 Accuracy

Accuracy merupakan metrik evaluasi yang paling umum digunakan pada permasalahan klasifikasi untuk mengukur persentase prediksi yang benar terhadap keseluruhan data uji. Nilai *accuracy* diperoleh dengan membandingkan jumlah prediksi yang benar, yaitu *True Positive* (TP) dan *True Negative* (TN), terhadap total seluruh data yang dievaluasi. Semakin tinggi nilai *accuracy*, semakin baik kemampuan model dalam melakukan klasifikasi secara keseluruhan. Namun, metrik ini memiliki keterbatasan ketika digunakan pada *dataset* yang tidak seimbang (*imbalanced dataset*) karena dapat menghasilkan nilai yang tinggi meskipun model cenderung memprediksi satu kelas secara dominan. Oleh karena itu, *accuracy* umumnya digunakan bersama metrik evaluasi lainnya, seperti *precision*, *recall*, dan *F1-score*, agar performa model dapat dinilai secara lebih

komprehensif (Mohsen, 2023). Persamaan *accuracy* ditunjukkan pada Persamaan (2.X).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Keterangan:

- TP (*True Positive*) = jumlah data positif yang diprediksi benar.
- TN (*True Negative*) = jumlah data negatif yang diprediksi benar.
- FP (*False Positive*) = jumlah data negatif yang diprediksi sebagai positif.
- FN (*False Negative*) = jumlah data positif yang diprediksi sebagai negatif.

2.12.3 Precision

Precision merupakan metrik evaluasi yang digunakan untuk mengukur ketepatan model dalam memprediksi kelas positif. Secara khusus, precision menunjukkan proporsi data yang diprediksi sebagai gerakan push-up benar dan benar-benar termasuk ke dalam kelas tersebut. Nilai precision yang tinggi menunjukkan bahwa model memiliki tingkat kesalahan False Positive (FP) yang rendah sehingga jarang memberikan prediksi positif yang salah (false alarm). Metrik ini menjadi penting ketika kesalahan dalam mengklasifikasikan data negatif sebagai data positif dapat memberikan dampak yang merugikan bagi pengguna. Oleh karena itu, precision sering digunakan bersama metrik evaluasi lainnya untuk memberikan gambaran performa model secara lebih menyeluruh (Mohsen, 2023). Persamaan precision ditunjukkan pada Persamaan (2.X).

$$Precision = \frac{TP}{TP + FP}$$

Keterangan:

- TP (*True Positive*) = jumlah data positif yang diprediksi benar.
- FP (*False Positive*) = jumlah data negatif yang diprediksi sebagai positif.

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

2.12.4 Recall

Recall merupakan metrik evaluasi yang digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang benar-benar termasuk ke dalam kelas positif. Secara khusus, *recall* menunjukkan proporsi gerakan *push-up* benar yang berhasil dikenali dan diklasifikasikan dengan benar oleh model. Nilai *recall* yang tinggi menunjukkan bahwa model mampu meminimalkan jumlah *False Negative* (FN), yaitu kondisi ketika data positif diprediksi sebagai data negatif. Metrik ini menjadi penting ketika kesalahan berupa *False Negative* dapat memberikan dampak yang lebih besar, misalnya gerakan *push-up* yang benar atau tidak sesuai standar gagal dikenali oleh sistem. Oleh karena itu, *recall* digunakan bersama metrik evaluasi lainnya untuk memberikan gambaran yang lebih lengkap mengenai kemampuan model dalam mendeteksi kelas positif (Mohsen, 2023). Persamaan *recall* ditunjukkan pada Persamaan (2.X).

$$Recall = \frac{TP}{TP + FN}$$

Keterangan:

TP (*True Positive*) = jumlah data positif yang diprediksi benar.

FN (*False Negative*) = jumlah data positif yang diprediksi sebagai negatif.

2.12.5 F1-Score

F1-Score merupakan metrik evaluasi yang diperoleh dari rata-rata harmonis antara *precision* dan *recall*, sehingga mampu memberikan keseimbangan antara kedua metrik tersebut dalam satu nilai tunggal. Berbeda dengan *accuracy*, *F1-Score* lebih representatif untuk digunakan pada *dataset* yang memiliki distribusi kelas tidak seimbang (*imbalanced dataset*) karena mempertimbangkan nilai *False Positive* (FP) dan *False Negative* (FN) secara bersamaan. Nilai *F1-Score* yang tinggi menunjukkan bahwa model memiliki keseimbangan yang baik antara ketepatan dalam memberikan prediksi positif (*precision*) dan kemampuan menemukan seluruh data positif (*recall*). Oleh karena itu, metrik ini banyak digunakan untuk mengevaluasi performa model klasifikasi, terutama ketika kedua jenis kesalahan

tersebut sama-sama perlu diperhatikan. Persamaan *F1-Score* ditunjukkan pada Persamaan (2.X) (Mohsen, 2023).

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

Keterangan:

- **Precision** = proporsi data yang diprediksi positif dan benar-benar termasuk kelas positif.
- **Recall** = proporsi data positif yang berhasil dikenali dengan benar oleh model.

2.12.6 ROC-AUC

Receiver Operating Characteristic–Area Under the Curve (ROC-AUC) merupakan metrik evaluasi yang digunakan untuk mengukur kemampuan model dalam membedakan kelas positif dan kelas negatif pada berbagai nilai *threshold*. Kurva *Receiver Operating Characteristic (ROC)* dibentuk dengan memplot *True Positive Rate (TPR)* atau *recall* pada sumbu vertikal terhadap *False Positive Rate (FPR)* pada sumbu horizontal untuk setiap nilai *threshold* yang mungkin. Sementara itu, *Area Under the Curve (AUC)* merupakan luas area di bawah kurva *ROC* yang merepresentasikan kemampuan model dalam membedakan kedua kelas secara keseluruhan. Nilai *ROC-AUC* berada pada rentang 0 hingga 1, di mana nilai 0,5 menunjukkan bahwa performa model setara dengan tebakan acak (*random guess*), nilai di atas 0,8 menunjukkan performa yang baik, sedangkan nilai yang mendekati 1,0 menunjukkan kemampuan klasifikasi yang sangat baik. Keunggulan *ROC-AUC* dibandingkan metrik evaluasi lainnya adalah kemampuannya mengevaluasi performa model secara menyeluruh tanpa bergantung pada satu nilai *threshold* tertentu. Oleh karena itu, *ROC-AUC* banyak digunakan sebagai metrik evaluasi pada permasalahan klasifikasi biner untuk menilai kemampuan model dalam membedakan setiap kelas secara lebih komprehensif (Mohsen, 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 menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Persamaan yang digunakan untuk membentuk kurva *ROC* ditunjukkan pada Persamaan (2.X) dan Persamaan (2.X).

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

Keterangan:

- *TPR (True Positive Rate)* = proporsi data positif yang berhasil diprediksi dengan benar (*recall*).
- *FPR (False Positive Rate)* = proporsi data negatif yang keliru diprediksi sebagai data positif.
- *TP (True Positive)* = jumlah data positif yang diprediksi benar.
- *TN (True Negative)* = jumlah data negatif yang diprediksi benar.
- *FP (False Positive)* = jumlah data negatif yang diprediksi sebagai positif.
- *FN (False Negative)* = jumlah data positif yang diprediksi sebagai negatif.

2.13 Kotlin

Kotlin merupakan bahasa pemrograman modern yang bersifat *statically typed* dan *general-purpose* serta berjalan di atas *Java Virtual Machine (JVM)*. Bahasa pemrograman ini dikembangkan untuk mengatasi berbagai keterbatasan yang dimiliki oleh *Java* tanpa menghilangkan kompatibilitas dengan ekosistem yang telah ada. Sejak tahun 2017, Google secara resmi menetapkan *Kotlin* sebagai bahasa utama dalam pengembangan aplikasi *Android* karena menawarkan sintaks yang lebih ringkas, aman, dan mudah dipelajari (Jemerov dan Isakova, 2017). Dukungan resmi tersebut menjadikan *Kotlin* semakin banyak digunakan dalam pengembangan aplikasi *mobile*, baik untuk kebutuhan akademis maupun industri. Oleh karena itu, *Kotlin* menjadi salah satu bahasa pemrograman yang paling populer dalam pengembangan aplikasi *Android* saat ini.

Kotlin menyediakan sintaks yang lebih sederhana dan ekspresif dibandingkan *Java*, sehingga proses pengembangan aplikasi dapat dilakukan dengan lebih efisien.

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

Bahasa ini juga dilengkapi dengan fitur *null safety* yang mampu mengurangi risiko terjadinya *NullPointerException*, yaitu salah satu penyebab umum *crash* pada aplikasi. Selain itu, *Kotlin* memiliki kemampuan *interoperability* yang sangat baik dengan berbagai *library* berbasis *Java*, sehingga pengembang dapat memanfaatkan ekosistem *Java* tanpa perlu melakukan perubahan yang signifikan. Kemampuan tersebut memungkinkan integrasi berbagai teknologi *machine learning*, termasuk *TensorFlow Lite*, ke dalam aplikasi *Android*. Penelitian ini memanfaatkan *Kotlin* sebagai bahasa pemrograman untuk mengembangkan aplikasi *Android* yang mengintegrasikan model *deep learning* sehingga proses evaluasi gerakan *push-up* dapat dilakukan secara *real-time*.

2.14 Black Box Testing

Black Box Testing merupakan metode pengujian perangkat lunak yang berfokus pada pemeriksaan fungsi sistem tanpa memperhatikan struktur maupun proses internal perangkat lunak. Metode ini memperlakukan perangkat lunak sebagai sebuah "*black box*", sehingga penguji hanya berinteraksi melalui masukan (*input*) dan mengamati keluaran (*output*) yang dihasilkan. Tujuan utama *Black Box Testing* adalah memastikan bahwa setiap fungsi sistem berjalan sesuai dengan kebutuhan dan spesifikasi yang telah ditetapkan tanpa harus mengetahui implementasi kode program di dalamnya (Santi *et al.*, 2022). Pendekatan ini banyak digunakan pada tahap pengujian aplikasi karena mampu mengevaluasi fungsionalitas sistem dari sudut pandang pengguna. Oleh karena itu, *Black Box Testing* menjadi salah satu metode yang umum diterapkan untuk memastikan kualitas dan keandalan perangkat lunak sebelum digunakan.

Penelitian ini menerapkan *Black Box Testing* untuk menguji seluruh fungsi utama pada aplikasi evaluasi gerakan *push-up* berbasis *Android*. Pengujian dilakukan dengan memberikan berbagai masukan (*input*) kepada sistem, kemudian membandingkan keluaran (*output*) yang dihasilkan dengan hasil yang diharapkan. Proses pengujian meliputi verifikasi fungsi deteksi *pose* menggunakan *MoveNet*, proses klasifikasi gerakan menggunakan model *Bidirectional Gated Recurrent Unit* (*BiGRU*), serta penyajian hasil evaluasi kepada pengguna. Selain itu, setiap fitur aplikasi diuji untuk memastikan seluruh fungsi dapat berjalan sesuai dengan kebutuhan fungsional yang telah dirancang. Dengan demikian, *Black Box Testing* digunakan untuk memastikan bahwa aplikasi mampu beroperasi dengan baik serta memberikan hasil evaluasi gerakan *push-up* secara benar dan konsisten.

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

2.15 User Acceptance Testing (UAT)

User Acceptance Testing (UAT) merupakan metode pengujian perangkat lunak yang dilakukan oleh pengguna akhir (*end user*) untuk memverifikasi apakah sistem yang dikembangkan telah memenuhi kebutuhan dan ekspektasi pengguna sesuai dengan tujuan awal pengembangan. Berbeda dengan *Black Box Testing* yang berfokus pada pengujian fungsionalitas sistem, *UAT* lebih menekankan pada penilaian dari sudut pandang pengguna, seperti kemudahan penggunaan, kesesuaian fungsi, dan tingkat penerimaan terhadap sistem. *User Acceptance Testing* merupakan tahap pengujian terakhir sebelum sistem dinyatakan layak digunakan dalam kondisi nyata (Cioroica *et al.*, 2019).

Penelitian ini menerapkan *User Acceptance Testing* dengan melibatkan pelatih kebugaran yang memiliki kompetensi dalam mengevaluasi gerakan *push-up*. Pengguna diminta mencoba aplikasi secara langsung, kemudian memberikan penilaian terhadap kemudahan penggunaan, kesesuaian fungsi, dan hasil yang diberikan oleh sistem. Hasil pengujian tersebut digunakan untuk mengetahui tingkat penerimaan pengguna terhadap aplikasi yang telah dikembangkan.

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 menerapkan pendekatan kuantitatif dengan jenis penelitian riset eksperimental. Pendekatan ini dipilih karena bertujuan untuk mengukur dan menguji performa model secara objektif menggunakan data numerik yang diperoleh melalui serangkaian eksperimen. Rancangan penelitian yang digunakan sebagai acuan dalam pengembangan sistem ditunjukkan pada Gambar 3.1. Selanjutnya, kebutuhan model dan kebutuhan aplikasi *Android* yang digunakan dalam penelitian ini dijelaskan pada Gambar 3.2.



Gambar 3. 1 Rancangan Penelitian Gerakan Push


A. Kebutuhan Model

Dataset video yang telah dibagi kemudian diproses menggunakan *MoveNet* untuk mendeteksi 17 titik *landmark* tubuh. Hasil deteksi tersebut selanjutnya diekstraksi menjadi 81 fitur pada setiap *frame* yang merepresentasikan posisi tubuh, sudut sendi, kecepatan gerakan, dan kelengkapan data *keypoint*. Data tersebut kemudian digunakan sebagai masukan bagi model *Bidirectional Gated Recurrent Unit* (*BiGRU*) yang dibangun menggunakan *framework TensorFlow*. Model

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

menghasilkan keluaran berupa hasil klasifikasi gerakan *push-up* ke dalam kategori benar atau salah beserta nilai probabilitas prediksinya.



Gambar 3. 2 Pembagian Dataset

Dataset video diproses terlebih dahulu oleh *MoveNet* untuk mendeteksi 17 titik *landmark* tubuh. Dari *landmark* tersebut diekstraksi 81 fitur per frame yang merepresentasikan posisi, sudut sendi, kecepatan gerakan, dan kelengkapan data *keypoint*. Data kemudian dilatih menggunakan arsitektur Bidirectional GRU (*BiGRU*) yang dibangun menggunakan framework TensorFlow. Model mampu memberikan hasil klasifikasi dan probabilitas apakah gerakan *push-up* yang dilakukan benar atau salah, dengan target akurasi di atas 80%.

B. Kebutuhan Aplikasi Android

Berikut adalah uraian mengenai kebutuhan fungsional dan non-fungsional untuk aplikasi Android yang dikembangkan:

1. Kebutuhan Fungsional

Kebutuhan fungsional merupakan fitur-fitur utama yang harus disediakan oleh aplikasi agar dapat menjalankan proses evaluasi gerakan *push-up*. Adapun kebutuhan fungsional yang dirancang adalah sebagai berikut.

- Sistem dapat mengakses kamera perangkat *Android* untuk merekam gerakan *push-up* pengguna sebagai masukan (*input*) proses evaluasi.

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 dapat menampilkan hasil klasifikasi gerakan *push-up* ke dalam kategori Benar atau Salah berdasarkan hasil inferensi model *Bidirectional Gated Recurrent Unit (BiGRU)*.
- Sistem dapat menampilkan umpan balik (*feedback*) berupa penjelasan mengenai hasil evaluasi gerakan sehingga pengguna dapat mengetahui bagian gerakan yang perlu diperbaiki.

2. Kebutuhan Nonfungsional

Kebutuhan nonfungsional merupakan kebutuhan yang berkaitan dengan kualitas sistem agar aplikasi dapat digunakan dengan baik. Adapun kebutuhan nonfungsional pada penelitian ini adalah sebagai berikut.

- Aplikasi mampu melakukan proses evaluasi gerakan dengan waktu respons yang cepat sehingga hasil dapat ditampilkan secara *real-time*.
- Antarmuka pengguna (*user interface*) dirancang sederhana dan mudah dipahami sehingga aplikasi dapat digunakan oleh berbagai kalangan pengguna.
- Aplikasi dapat berjalan pada perangkat *Android* yang mendukung penggunaan kamera dan *TensorFlow Lite*.

Setelah kebutuhan fungsional dan kebutuhan nonfungsional ditentukan, tahap selanjutnya adalah menyusun *use case diagram* sebagai gambaran interaksi antara pengguna dengan sistem. *Use case diagram* tersebut ditunjukkan pada Gambar 3.3.




Gambar 3. 3 Use Case Diagram Aplikasi

Berdasarkan Gambar 3.3, *use case diagram* menggambarkan interaksi antara pengguna dengan aplikasi evaluasi gerakan *push-up*. Pengguna sebagai aktor utama dapat menjalankan tiga fungsi utama, yaitu merekam gerakan *push-up* menggunakan kamera perangkat, melihat hasil evaluasi yang diklasifikasikan ke dalam kategori benar atau salah, serta melihat umpan balik (*feedback*) yang menjelaskan hasil evaluasi gerakan. *Use case diagram* ini menjadi dasar dalam perancangan fitur-fitur aplikasi sehingga seluruh kebutuhan fungsional yang telah ditetapkan dapat diimplementasikan sesuai dengan tujuan penelitian.

3.2 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang disusun secara sistematis untuk memastikan proses pengembangan model dan aplikasi berjalan secara terstruktur sesuai dengan tujuan penelitian. Tahapan penelitian yang dilakukan ditunjukkan pada Gambar 3.4:



Gambar 3. 4 Tahapan Penelitian

Penelitian diawali dengan tahap identifikasi masalah. Tahap ini bertujuan untuk mengidentifikasi permasalahan yang berkaitan dengan evaluasi gerakan *push-up*, khususnya masih terbatasnya sistem yang mampu melakukan penilaian gerakan secara otomatis, objektif, dan *real-time*. Selain itu, dilakukan analisis kebutuhan sistem sebagai dasar dalam menentukan spesifikasi model dan aplikasi yang akan 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 menggunakan 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 menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tahap berikutnya adalah studi literatur. Studi literatur dilakukan dengan mengkaji berbagai referensi ilmiah yang berkaitan dengan *pose estimation*, *deep learning*, *Bidirectional Gated Recurrent Unit (BiGRU)*, *feature engineering*, serta penelitian terdahulu mengenai analisis gerakan olahraga berbasis *computer vision*. Hasil kajian ini digunakan sebagai landasan teori sekaligus acuan dalam pengembangan sistem.

Tahap selanjutnya adalah pengumpulan dataset. Data yang digunakan berupa video gerakan *push-up* yang diperoleh melalui perekaman mandiri, platform berbagi video daring, dan *dataset* publik. Seluruh video kemudian divalidasi oleh pelatih kebugaran yang kompeten untuk memastikan kesesuaian gerakan dengan kategori benar maupun salah sebelum digunakan dalam proses penelitian.

Tahap berikutnya adalah pelabelan (*labeling*) dan *pre-processing*. Setiap video diberikan label sesuai dengan kualitas gerakannya, kemudian diproses menggunakan *MoveNet* untuk mendeteksi 17 *keypoint* tubuh. Hasil deteksi tersebut selanjutnya melalui proses *feature engineering* sehingga menghasilkan 81 fitur pada setiap *frame*. Setelah itu dilakukan augmentasi data pada *training data* serta normalisasi menggunakan metode *Z-Score Standardization* sebelum data digunakan sebagai masukan model.

Tahap berikutnya adalah pelatihan model. Model yang digunakan merupakan arsitektur *Bidirectional Gated Recurrent Unit (BiGRU)* yang dibangun menggunakan *TensorFlow*. Proses pelatihan dilakukan menggunakan *optimizer Adam*, fungsi *Binary Crossentropy* dengan *Label Smoothing*, *L2 Regularization*, serta *Early Stopping* untuk membantu meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*.

Setelah proses pelatihan selesai, dilakukan evaluasi model menggunakan *testing data*. Evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, *F1-score*, *ROC-AUC*, dan *confusion matrix*, sehingga performa model dapat dianalisis secara menyeluruh.

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

Tahap berikutnya adalah implementasi model pada aplikasi Android. Model yang telah dilatih dikonversi ke format *TensorFlow Lite* (.tflite) agar dapat dijalankan pada perangkat *Android*. Selanjutnya model diintegrasikan ke dalam aplikasi yang dikembangkan menggunakan bahasa pemrograman *Kotlin*. Aplikasi dirancang untuk mendeteksi pose pengguna secara *real-time*, melakukan klasifikasi gerakan *push-up*, serta menampilkan hasil evaluasi dan umpan balik kepada pengguna.

Tahap selanjutnya adalah pengujian aplikasi. Pengujian dilakukan menggunakan metode *Black Box Testing* untuk memastikan seluruh fungsi aplikasi berjalan sesuai dengan spesifikasi yang telah dirancang, serta *User Acceptance Testing* (UAT) untuk mengetahui tingkat penerimaan pengguna terhadap aplikasi yang dikembangkan.

Tahap terakhir adalah penarikan kesimpulan dan penyusunan laporan penelitian. Kesimpulan disusun berdasarkan hasil pengujian model dan aplikasi, kemudian seluruh proses penelitian didokumentasikan dalam bentuk laporan sebagai hasil akhir penelitian.

3.2.1 Identifikasi Masalah

Pada tahap awal ini, dilakukan perumusan masalah berdasarkan latar belakang mengenai risiko cedera pada latihan *push-up* tanpa pengawasan dan kurangnya feedback mengenai teknik yang benar. Tahap ini bertujuan menentukan fokus penelitian, yaitu pengembangan sistem evaluasi otomatis berbasis Android menggunakan *deep learning* untuk mengklasifikasikan kualitas gerakan *push-up*.

3.2.2 Studi Literatur

Tahap ini melibatkan pengumpulan referensi teori dan penelitian terdahulu yang relevan, meliputi topik gerakan *push-up*, *Human Pose Estimation* menggunakan *MoveNet*, algoritma *deep learning* berbasis *BiGRU*, teknik *feature engineering* dari *keypoint* tubuh, metrik evaluasi model, serta pengembangan aplikasi Android menggunakan *Kotlin* dan *TensorFlow Lite*.

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

3.2.3 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan melalui tiga sumber utama, yaitu dataset publik, perekaman secara mandiri, serta video yang diperoleh dari platform berbagi video daring. Seluruh data yang dikumpulkan kemudian melalui proses seleksi berdasarkan kualitas video, kejelasan gerakan *push-up*, serta kesesuaian sudut pengambilan gambar agar dapat digunakan dalam proses pelatihan dan pengujian model.

1. Dataset Publik (*Kaggle*)

Sebanyak 100 video diperoleh dari dataset publik yang tersedia pada platform *Kaggle*. Dataset ini dipilih karena menyediakan video gerakan *push-up* dengan variasi gerakan benar dan salah serta memiliki kualitas video yang cukup baik sehingga sesuai untuk proses ekstraksi pose menggunakan MoveNet.

2. Perekaman Secara Mandiri (*Self-recording*)

Sebanyak 30 video direkam secara mandiri dengan melibatkan beberapa partisipan yang melakukan gerakan *push-up* benar maupun salah. Proses perekaman dilakukan menggunakan kamera telepon pintar dengan posisi kamera tetap (statis), kondisi pencahayaan yang cukup, serta latar belakang yang relatif sederhana untuk meminimalkan gangguan pada proses deteksi pose tubuh.

3. Platform Berbagi Video Daring

Sebanyak 90 video dikumpulkan dari platform berbagi video daring, yaitu 50 video yang diperoleh dari YouTube dan 40 video yang diperoleh dari TikTok. Video yang dipilih merupakan video yang dapat diakses secara publik serta memenuhi kriteria penelitian, seperti memiliki kualitas visual yang baik, menampilkan gerakan *push-up* secara utuh dari awal hingga akhir, dan memiliki sudut pengambilan gambar yang sesuai sehingga dapat digunakan dalam proses ekstraksi pose menggunakan MoveNet.

Secara keseluruhan, dataset yang digunakan dalam penelitian ini berjumlah 220 video yang terdiri atas dua kategori gerakan, yaitu 110 video gerakan *push-up* benar

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

dan 110 video gerakan *push-up* salah. Pembagian jumlah data yang seimbang pada kedua kategori bertujuan untuk menghindari ketidakseimbangan kelas (*class imbalance*) yang dapat memengaruhi performa model klasifikasi. Selain itu, video juga dikelompokkan berdasarkan dua sudut pandang pengambilan gambar, yaitu *front view* (depan) dan *side view* (samping), sehingga model dapat mempelajari variasi posisi tubuh dari berbagai perspektif dan memiliki kemampuan generalisasi yang lebih baik ketika digunakan pada kondisi nyata. Distribusi dataset berdasarkan sudut pandang ditunjukkan pada Tabel 3.1,

Tabel 3. 1 Distribusi Dataset Berdasarkan Sudut Pandang

Sudut Pandang	Benar	Salah	Total
<i>Front View</i> (Depan)	49	37	86
<i>Side View</i> (Samping)	61	73	134
Total	110	110	220

Adapun rincian sumber data yang digunakan dalam penelitian ini disajikan pada Tabel 3.2. Tabel tersebut menunjukkan jumlah video yang diperoleh dari masing-masing sumber sehingga memberikan gambaran mengenai komposisi dataset yang digunakan dalam proses pelatihan dan pengujian mode.

Tabel 3. 2 Distribusi Dataset Berdasarkan Sumber

Sumber Data	Jumlah Video
Dataset Kaggle	100
Perekaman Mandiri	30
YouTube	50
TikTok	40
Total	220

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

Seluruh video yang telah diperoleh dari berbagai sumber kemudian melalui proses seleksi dan penyesuaian format agar memiliki karakteristik yang seragam sebelum dilakukan ekstraksi *keypoint* menggunakan MoveNet. Tahap ini bertujuan untuk memastikan bahwa data yang digunakan memiliki kualitas yang baik dan mampu mendukung proses pelatihan model BiGRU secara optimal.

3.2.4 Validasi Dataset

Setelah seluruh data terkumpul, dilakukan proses validasi dataset oleh Mba Indah, pelatih kebugaran bersertifikat dari Aka Gym Fitness, yang memiliki pengalaman dan kompetensi dalam bidang latihan fisik. Validasi dilakukan untuk memastikan bahwa setiap video dengan label benar (1) memenuhi kriteria teknik *push-up* yang tepat, sedangkan video dengan label salah (0) menunjukkan kesalahan teknik yang dapat diidentifikasi. Kriteria penilaian yang digunakan meliputi posisi tubuh lurus dari kepala hingga tumit, sudut siku sekitar 90 derajat saat fase turun, posisi tangan sejajar dengan bahu, serta tidak terdapat kompensasi gerakan pada bagian pinggang maupun kepala. Video yang tidak memenuhi kriteria penilaian secara jelas dikeluarkan dari dataset untuk menjaga kualitas data latih.

3.2.5 Pre-Processing Data

Data video mentah tidak dapat langsung diproses oleh model BiGRU. Oleh karena itu, diperlukan tahapan *pre-processing* data untuk mengubah data video menjadi representasi numerik yang siap digunakan sebagai masukan model. Tahapan *pre-processing* dilakukan secara berurutan, dimulai dari pemberian label pada setiap video, ekstraksi fitur menggunakan MoveNet Thunder, augmentasi data untuk memperbanyak variasi data latih, pemotongan video menjadi sekuens dengan durasi tetap menggunakan *sliding window*, normalisasi menggunakan *Z-Score Standardization*, hingga pembagian dataset menggunakan *stratified split*. Setiap tahapan dijelaskan sebagai berikut:

3.2.5.1 Labeling Data

Setelah data video terkumpul dan divalidasi, dilakukan proses *labeling* atau pemberian label pada setiap video. Setiap video diberikan label 1 apabila gerakan

push-up dinilai benar, dan label 0 apabila gerakan *push-up* dinilai salah. Proses *labeling* mengacu pada hasil validasi yang telah dilakukan oleh pelatih kebugaran bersertifikat pada tahap sebelumnya.

3.2.5.2 Ekstraksi Fitur (Feature Engineering)

Video diproses menggunakan MoveNet Thunder untuk mendeteksi 17 titik *landmark* tubuh dalam koordinat 2D (x, y). Berdasarkan *keypoint* mentah yang dihasilkan oleh MoveNet, dilakukan *feature engineering* untuk menghasilkan 81 fitur pada setiap *frame*. Fitur-fitur tersebut mencakup berbagai aspek gerakan tubuh, mulai dari posisi koordinat, sudut sendi, tingkat keyakinan deteksi, hingga kecepatan gerakan antar *frame*. Rincian lengkap mengenai 81 fitur pada setiap *frame* yang digunakan dalam penelitian ini telah dijelaskan pada BAB II Tabel 2.3. Tabel 3.3 menyajikan kembali ringkasan fitur tersebut sebagai acuan dalam proses *pre-processing*.

Tabel 3. 3 Rincian 81 Fitur per Frame

Kelompok Fitur	Jumlah	Indeks
Koordinat x, y (17×2)	34	0–33
Sudut biomekanik	10	34–43
Confidence score	17	44–60
Missing flags (lower body)	6	61–66
Velocity antar frame	12	67–78
Fitur khusus push-up	2	79–80
Total	81	0–80

Berdasarkan Tabel 3.3, sebanyak 81 fitur digunakan untuk merepresentasikan karakteristik gerakan *push-up* dalam bentuk data numerik. Fitur tersebut terdiri atas informasi posisi tubuh melalui koordinat *keypoint*, informasi biomekanik melalui perhitungan sudut sendi, tingkat keyakinan deteksi dari MoveNet, indikator titik tubuh yang tidak terdeteksi, perubahan posisi antar *frame*, serta fitur khusus yang berkaitan dengan pola gerakan *push-up*. Seluruh fitur tersebut kemudian digunakan

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

sebagai masukan pada tahap pemrosesan berikutnya sebelum dilakukan pelatihan model BiGRU.

3.2.5.3 Augmentasi Data

Untuk mengatasi keterbatasan jumlah data, dilakukan augmentasi data sebanyak $3\times$ sehingga setiap video menghasilkan tiga versi data, yaitu data asli, data dengan penambahan *noise* acak kecil, dan data dengan perubahan skala koordinat. Augmentasi hanya diterapkan pada data pelatihan (*training data*) dan tidak diterapkan pada data validasi (*validation data*) maupun data pengujian (*testing data*) untuk menjaga objektivitas evaluasi model.

3.2.5.4 Fixed Window 30 Frame

Setiap video dipotong menjadi beberapa sekuens menggunakan metode *sliding window* dengan panjang tetap sebanyak 30 *frame*. Pada data pelatihan, metode *sliding window* diterapkan dengan *stride* sebesar 22 *frame* (*overlap* 25%) untuk meningkatkan variasi data yang digunakan selama proses pelatihan model. Sementara itu, pada data validasi dan data pengujian digunakan *stride* sebesar 30 *frame* (tanpa *overlap*), sehingga setiap *frame* hanya termasuk dalam satu sekuens. Dengan pendekatan ini, satu video dapat menghasilkan lebih dari satu sekuens bergantung pada jumlah *frame* yang dimiliki. Selanjutnya, setiap sekuens diperlakukan sebagai satu sampel data dan diklasifikasikan secara independen oleh model.

3.2.5.5 Normalisasi Data

Setelah proses *feature engineering*, seluruh 81 fitur hasil ekstraksi *keypoint* distandardisasi menggunakan metode *Z-Score Standardization* dengan memanfaatkan *StandardScaler* dari *library* scikit-learn. Standardisasi dilakukan berdasarkan nilai *mean* dan *standard deviation* yang diperoleh dari data pelatihan (*training set*), kemudian parameter tersebut diterapkan pada data validasi dan data pengujian untuk mencegah terjadinya *data leakage*. Tahap ini bertujuan untuk menyeragamkan skala antarfitur sehingga proses pelatihan model BiGRU menjadi lebih stabil dan mampu mempelajari pola data secara lebih efektif. Hasil

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

standardisasi selanjutnya digunakan sebagai masukan pada proses pembentukan sekuens menggunakan metode *sliding window*.

3.2.5.6 Stratified Split

Dataset dibagi menggunakan metode stratified split dengan proporsi tetap 70/15/15 untuk memastikan proporsi kelas benar dan salah tetap seimbang di setiap subset data seperti pada Tabel 3.4.

Tabel 3. 4 Pembagian Dataset

Subset	Persentase	Jumlah Video
Training	70%	154 Video
Validation	15%	33 Video
Testing	15%	33 Video
Total	100%	220 Video

Pembagian data dengan proporsi 70/15/15 dipilih sebagai skema utama setelah dibandingkan dengan skema 80/10/10 yang diimplementasikan dengan arsitektur dan hyperparameter yang identik. Tabel 3.5 menyajikan perbandingan hasil kedua skema tersebut.

Tabel 3. 5 Perbandingan Skema 70/15/15 vs 80/10/10

Metrik	70/15/15	80/10/10
Mean test accuracy	72,08%	65,81%
Best test accuracy	85,36%	70,42%
Mean test F1-score	71,46%	65,66%

Skema 70/15/15 menghasilkan mean test accuracy yang lebih tinggi (72,08%) dibandingkan skema 80/10/10 (65,81%). Best run accuracy pada 70/15/15 mencapai 85,36%, melampaui best run 80/10/10 yang hanya mencapai 70,42%. Skema 80/10/10 justru menunjukkan performa yang lebih rendah meskipun menerima lebih banyak data latih, yang mengindikasikan bahwa jumlah data

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

validasi yang cukup sangat penting untuk menghasilkan generalisasi model yang baik.

Skema 90/5/5 tidak digunakan dalam penelitian ini karena dengan total 220 video, proporsi 5% hanya setara dengan 11 video untuk validasi dan 11 untuk pengujian. Jumlah tersebut terlalu sedikit untuk memberikan estimasi performa yang stabil secara statistik. Dengan demikian, skema 70/15/15 dipilih sebagai skema utama karena memberikan keseimbangan terbaik antara jumlah data latih yang cukup dengan data validasi dan pengujian yang representatif.

3.2.5.7 Pembuatan Model


Model yang dikembangkan menggunakan arsitektur *Bidirectional GRU* (BiGRU). Pemilihan BiGRU didasarkan pada kemampuannya dalam memproses data sekuensial dari dua arah secara bersamaan, yaitu arah maju (*forward*) dan arah mundur (*backward*), sehingga konteks gerakan dapat dipahami secara lebih menyeluruh dibandingkan dengan GRU biasa. Arsitektur model dirancang dengan dua lapisan utama, yaitu lapisan BiGRU pertama dengan 48 unit yang bertugas mengekstraksi representasi fitur temporal dari dua arah, serta lapisan GRU kedua dengan 24 unit yang bertugas meringkas informasi menjadi representasi yang lebih padat sebelum diteruskan ke lapisan klasifikasi. Jumlah unit yang relatif kecil dipilih secara sengaja untuk mengurangi risiko *overfitting* mengingat ukuran dataset yang terbatas, sekaligus memastikan model tetap ringan dan efisien saat dijalankan pada perangkat *mobile*.

Sebelum data masuk ke lapisan rekuren, diterapkan lapisan *Masking* untuk menangani *frame* yang tidak terdeteksi akibat keterbatasan sudut pandang kamera. Selain itu, lapisan *GaussianNoise* dengan nilai deviasi standar kecil digunakan untuk meningkatkan ketahanan model terhadap variasi gerakan yang tidak sempurna. Setiap lapisan rekuren dilengkapi dengan *BatchNormalization* untuk menstabilkan distribusi aktivasi selama proses pelatihan serta *Dropout* untuk mengurangi ketergantungan berlebihan terhadap neuron tertentu. Lapisan *Dense* dengan 16 unit dan fungsi aktivasi *ReLU* digunakan untuk menggabungkan informasi temporal sebelum diteruskan ke lapisan keluaran. Lapisan keluaran

menggunakan fungsi aktivasi *sigmoid* yang menghasilkan nilai probabilitas antara 0 dan 1, dengan nilai mendekati 1 menunjukkan gerakan *push-up* benar dan nilai mendekati 0 menunjukkan gerakan *push-up* salah. Untuk memastikan *reproducibility* hasil pelatihan, digunakan *random seed* yang mengatur proses inisialisasi bobot model dan pembagian dataset sehingga proses pelatihan dapat menghasilkan hasil yang konsisten dan dapat direproduksi.

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. 5 Arsitektur Model

Gambar 3.5 menunjukkan arsitektur model yang digunakan dalam penelitian ini. *Input layer* menerima data dalam bentuk sekuens dengan dimensi (30, 81), yaitu 30 *frame* dengan 81 fitur pada setiap *frame*. Data tersebut kemudian diproses oleh lapisan BiGRU pertama dengan 48 unit yang membaca sekuens dari dua arah sehingga mampu menghasilkan representasi fitur temporal yang lebih kaya. Keluaran dari lapisan tersebut selanjutnya diproses melalui *Batch Normalization* dan *Dropout* sebesar 0,5 untuk meningkatkan stabilitas pelatihan serta mengurangi risiko terjadinya *overfitting*. Data kemudian diteruskan ke lapisan GRU kedua dengan 24 unit untuk meringkas informasi menjadi representasi fitur yang lebih padat. Selanjutnya, *Dense Layer* menggabungkan informasi temporal yang telah dipelajari sebelum diteruskan ke *Output Layer*. Lapisan keluaran menggunakan fungsi aktivasi *sigmoid* untuk menghasilkan nilai probabilitas yang menentukan klasifikasi gerakan *push-up* sebagai benar (1) atau salah (0).

Untuk memperoleh performa model yang optimal, proses pelatihan dilakukan menggunakan beberapa parameter dan konfigurasi yang telah ditentukan berdasarkan hasil eksperimen awal serta karakteristik dataset yang digunakan. Konfigurasi tersebut meliputi parameter arsitektur model, fungsi aktivasi, *optimizer*, fungsi *loss*, ukuran *batch (batch size)*, jumlah *epoch*, serta parameter lain yang memengaruhi proses pembelajaran model. Rincian konfigurasi model yang digunakan dalam penelitian ini disajikan pada Tabel 3.6.

Tabel 3. 6 Konfigurasi Model

Parameter	Nilai
Arsitektur	<i>BiGRU</i> 48 + GRU 24 + BatchNorm + Dropout
Input	30 frame × 81 fitur
Optimizer	Adam (lr = 0.0005)
Loss Function	Binary Crossentropy + Label Smoothing 0.05
Batch Size	16
Max Epoch	200
EarlyStopping Patience	40 epoch
Dropout Layer 1 & 2	0.5

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 menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Parameter	Nilai
Dropout Dense	0.4
L2 Regularization	0.001
Augmentasi	3× (noise + scale)
Split	70% / 15% / 15% (stratified)

Proses pelatihan menggunakan *EarlyStopping* yang memantau *validation accuracy* dengan nilai *patience* sebesar 40 *epoch*. Pelatihan berhenti secara otomatis pada *epoch* ke-57 dari maksimum 200 *epoch*, yang menunjukkan bahwa model telah mencapai kondisi optimal sebelum mengalami peningkatan risiko *overfitting*.

3.2.7 Evaluasi Model

Model yang telah dilatih dievaluasi menggunakan data pengujian (*testing data*) yang tidak pernah digunakan oleh model selama proses pelatihan. Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, *ROC-AUC*, dan *confusion matrix* sebagaimana dijelaskan pada BAB II Subbab 2.11. Target minimum performa yang ingin dicapai dalam penelitian ini adalah nilai akurasi sebesar 80% atau lebih tinggi.

3.2.8 Integrasi dan Pengembangan Aplikasi Android

Model terbaik yang telah melalui tahap evaluasi dikonversi ke dalam format TensorFlow Lite (.tflite) agar dapat dijalankan secara efisien pada perangkat Android. Pengembangan aplikasi dilakukan menggunakan Android Studio dengan bahasa pemrograman Kotlin. Tahap ini meliputi pembuatan antarmuka pengguna yang intuitif, integrasi MoveNet untuk melakukan deteksi pose secara *real-time*, serta implementasi model BiGRU untuk melakukan proses inferensi secara langsung melalui kamera telepon pintar. Aplikasi yang dikembangkan dilengkapi dengan fitur untuk menampilkan *skeleton overlay* pada layar serta memberikan hasil klasifikasi dan nilai probabilitas prediksi kepada pengguna.

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

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

3.2.9 Pengujian (*Testing*)

Aplikasi yang telah dikembangkan diuji menggunakan dua metode pengujian. Pertama, *Black Box Testing* yang berfokus pada pengujian fungsionalitas aplikasi untuk memastikan bahwa fitur deteksi pose menggunakan MoveNet, klasifikasi gerakan menggunakan model BiGRU, serta tampilan hasil evaluasi berjalan sesuai dengan spesifikasi yang telah ditentukan. Kedua, *User Acceptance Testing* (UAT) yang dilakukan oleh pelatih kebugaran bersertifikat dari pusat kebugaran untuk menilai kesesuaian hasil klasifikasi gerakan *push-up* yang dihasilkan aplikasi dengan penilaian ahli, serta mengevaluasi tingkat kemudahan penggunaan aplikasi secara keseluruhan.

3.2.10 Kesimpulan dan Pembuatan Laporan

Tahap ini merupakan tahap akhir dari penelitian. Setelah seluruh proses selesai dilakukan, penarikan kesimpulan dilakukan berdasarkan hasil pengujian model dan aplikasi, analisis performa model BiGRU dalam mengklasifikasikan gerakan *push-up*, serta penyusunan laporan penelitian sebagai bentuk dokumentasi yang mencakup seluruh metodologi, hasil eksperimen, dan rekomendasi untuk pengembangan lebih lanjut.



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 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini terdiri atas 220 video gerakan *push-up* yang diperoleh dari tiga sumber, yaitu dataset publik Kaggle, perekaman secara mandiri, dan platform berbagi video daring. Setiap video diproses menggunakan model MoveNet Thunder untuk mendeteksi 17 titik tubuh (*keypoint*) pada setiap *frame*. *Keypoint* yang dihasilkan kemudian digunakan dalam proses ekstraksi fitur sebagai masukan bagi model *Bidirectional Gated Recurrent Unit* (BiGRU). Untuk menjaga representasi data selama proses pembagian dataset, seluruh video dikelompokkan ke dalam beberapa strata berdasarkan sudut pengambilan gambar dan label gerakan. Selain itu, dilakukan analisis terhadap beberapa skema *stratified split* guna menentukan konfigurasi pembagian data yang mampu memberikan representasi strata yang baik untuk proses pelatihan dan evaluasi model.

4.1.1 Distribusi Dataset Berdasarkan Strata

Dataset yang digunakan dalam penelitian ini terdiri atas 220 video yang dikelompokkan ke dalam empat strata berdasarkan kombinasi sudut pandang pengambilan video, yaitu *side view* dan *front view*, serta label gerakan, yaitu benar dan salah. Pengelompokan tersebut dilakukan untuk memastikan bahwa setiap kombinasi antara sudut pandang dan kelas gerakan tetap terwakili pada setiap subset data yang dihasilkan melalui proses pembagian dataset. Distribusi jumlah video pada masing-masing strata disajikan pada Tabel 4.1.

Tabel 4. 1 Distribusi Dataset per Strata

View	Label	Jumlah Video	Persentase
Side	Benar	61	27,7%
Side	Salah	73	33,2%
Front	Benar	49	22,3%

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

View	Label	Jumlah Video	Persentase
Front	Salah	37	16,8%
Total		220	100%

Berdasarkan Tabel 4.1, jumlah video pada setiap strata tidak sepenuhnya sama. Strata *Side-Salah* memiliki jumlah video terbanyak, yaitu 73 video (33,2%), sedangkan strata *Front-Salah* memiliki jumlah video paling sedikit, yaitu 37 video (16,8%). Meskipun terdapat perbedaan jumlah sampel antarstrata, seluruh strata tetap memiliki jumlah data yang memadai sehingga dapat digunakan dalam proses pembagian dataset menggunakan metode *stratified split*. Dengan demikian, setiap subset data tetap mempertahankan keberadaan seluruh kombinasi sudut pandang dan label gerakan.

Ditinjau berdasarkan label gerakan, dataset terdiri atas 110 video gerakan benar dan 110 video gerakan salah sehingga distribusi kedua kelas berada dalam kondisi seimbang. Keseimbangan distribusi kelas ini penting untuk mengurangi potensi *class imbalance* yang dapat menyebabkan model lebih cenderung mempelajari salah satu kelas dibandingkan kelas lainnya. Dengan distribusi kelas yang seimbang, proses pelatihan diharapkan mampu menghasilkan model dengan kemampuan generalisasi yang lebih baik dalam membedakan gerakan *push-up* benar dan salah.

4.1.2 Validitas Stratified Split

Sebelum proses pelatihan model dilakukan, validitas skema *stratified split* dievaluasi menggunakan 500 *Monte Carlo trials*. Pendekatan ini digunakan untuk menguji kestabilan konfigurasi pembagian data melalui proses pengambilan sampel ulang secara berulang. Metode *Monte Carlo* dapat digunakan sebagai pendekatan evaluasi berbasis *resampling* yang sesuai untuk kondisi dataset dengan jumlah sampel terbatas, karena mampu memberikan estimasi performa yang lebih reliabel melalui pengulangan simulasi dengan jumlah tertentu (Shan, 2022).

Evaluasi dilakukan untuk memastikan bahwa setiap konfigurasi pembagian data mampu mempertahankan proporsi keempat strata berdasarkan kombinasi sudut pandang dan label gerakan pada data pelatihan, validasi, dan pengujian. Parameter yang digunakan adalah *minimum strata count* (*min_strata_min*), yaitu jumlah sampel paling sedikit dari seluruh strata yang terdapat pada subset validasi maupun pengujian setelah proses pembagian data. Semakin besar nilai *min_strata_min*, semakin baik keterwakilan setiap strata sehingga hasil evaluasi model menjadi lebih stabil dan representatif.

Kelayakan setiap konfigurasi ditentukan berdasarkan jumlah sampel minimum pada masing-masing strata. Kriteria yang digunakan dalam penelitian ini menetapkan konfigurasi sebagai Layak apabila setiap strata memiliki sedikitnya lima sampel pada data validasi maupun pengujian. Konfigurasi dikategorikan Marginal apabila terdapat strata dengan jumlah tiga hingga empat sampel, sedangkan konfigurasi dinyatakan Tidak Layak apabila terdapat strata dengan jumlah sampel dua atau kurang. Penetapan batas tersebut digunakan sebagai kriteria evaluasi internal penelitian untuk memastikan setiap strata memiliki jumlah sampel yang cukup dalam proses evaluasi model.

Tabel 4. 2 menunjukkan hasil analisis untuk 9 konfigurasi rasio split.

Split	Test Strata Min	Val Strata Min	Status
60/20/20	7	7	Layak
65/20/15	6	7	Layak
70/10/20	7	4	Marginal
70/15/15	6	6	Layak
70/20/10	4	7	Marginal
75/15/10	4	6	Marginal
80/10/10	4	4	Marginal
85/10/05	2	4	Tidak layak
90/05/05	2	2	Tidak layak

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

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 Tabel 4.2, konfigurasi 60/20/20, 65/20/15, dan 70/15/15 memenuhi kriteria Layak karena setiap strata memiliki sedikitnya lima sampel pada data validasi maupun pengujian. Di antara ketiga konfigurasi tersebut, skema 70/15/15 dipilih sebagai konfigurasi akhir karena memberikan keseimbangan yang lebih baik antara jumlah data pelatihan, validasi, dan pengujian. Proporsi data pelatihan sebesar 70% menyediakan jumlah sampel yang cukup untuk proses pembelajaran model, sementara 15% data validasi memberikan jumlah sampel yang memadai untuk mendukung mekanisme *Early Stopping* dan pemilihan model terbaik. Selain itu, alokasi 15% data pengujian tetap menyediakan jumlah sampel yang representatif untuk mengevaluasi kemampuan generalisasi model secara independen.

4.2 Skenario Pengujian

Pengujian *split ratio* dilakukan untuk memvalidasi secara eksperimental pemilihan rasio pembagian data yang telah ditentukan pada tahap perancangan. Setiap skenario menggunakan arsitektur model dan konfigurasi *hyperparameter* yang sama, kemudian proses pelatihan dilakukan sebanyak lima kali menggunakan *seed* yang berbeda untuk memperoleh gambaran performa model yang lebih stabil.

Berdasarkan hasil pengujian, rasio 70/15/15 menghasilkan performa terbaik dengan *mean accuracy* sebesar 72,1%, *best accuracy* mencapai 85,4%, serta rata-rata kesenjangan antara *training accuracy* dan *validation accuracy* sebesar 7,6%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Oleh karena itu, pembagian data dengan proporsi 70% *training*, 15% *validation*, dan 15% *testing* dipilih sebagai konfigurasi utama yang digunakan pada seluruh eksperimen dalam penelitian ini.

4.3 Hasil Pelatihan Model

Setelah dataset dinyatakan layak digunakan, tahap selanjutnya adalah melatih model BiGRU untuk melakukan klasifikasi kualitas gerakan push-up. Proses pelatihan mengikuti rancangan yang telah dijelaskan pada BAB III menggunakan konfigurasi *hyperparameter* sebagaimana ditunjukkan pada Tabel 4.3.

Tabel 4. 3 Hyperparameter Pelatihan Model

Hyperparameter	Nilai	Hyperparameter	Nilai
GRU Units	48 (Bidirectional) + 24	GRU Units	48 (Bidirectional) + 24
Dropout	0,5	Dropout	0,5
L2 Regularization	0,001	L2 Regularization	0,001
Learning Rate	0,0005	Learning Rate	0,0005
Batch Size	16	Batch Size	16
Epoch Maksimal	200	Epoch Maksimal	200
Label Smoothing	0,05	Label Smoothing	0,05
Augmentasi Multiplier	3× (original + noise + scale)	Augmentasi Multiplier	3× (original + noise + scale)
Overlap Train	25%	Overlap Train	25%
Lower Body Smoothing	Ya	Lower Body Smoothing	Ya
Early Stopping Patience	40 epoch	Early Stopping Patience	40 epoch
ReduceLROnPlateau Patience	15 epoch	ReduceLROnPlateau Patience	15 epoch

Pelatihan dilakukan sebanyak tiga kali menggunakan seed yang berbeda untuk mengevaluasi konsistensi performa model terhadap variasi inisialisasi bobot. Setiap run menghasilkan jumlah epoch aktual yang berbeda karena mekanisme EarlyStopping akan menghentikan proses pelatihan secara otomatis apabila tidak terjadi peningkatan pada performa validasi. Hasil pelatihan ketiga run ditunjukkan pada Tabel 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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4. 4 Hasil Pelatihan Model BiGRU

Run	Epoch	Train Acc	Val Acc	Gap	Val Loss	Test Acc
1	119	99,57%	84,51%	15,06%	0,6449	64,88%
2	42	65,41%	70,19%	-4,78%	0,8976	66,00%
3	57	97,77%	85,37%	12,40%	0,6067	85,36%

Berdasarkan Tabel 4.4, model terbaik yang dihasilkan adalah Run 3 dengan test accuracy sebesar 85,36% dan validation loss terendah sebesar 0,6067. Nilai tersebut telah melampaui target minimum akurasi sebesar 80% yang ditetapkan pada penelitian ini. Run 1 menunjukkan gejala overfitting, ditandai dengan training accuracy sebesar 99,57%, namun hanya memperoleh test accuracy sebesar 64,88%. Kondisi tersebut menunjukkan bahwa model terlalu menyesuaikan diri terhadap data pelatihan sehingga kemampuan generalisasinya menurun (Goodfellow et al., 2016). Sebaliknya, Run 2 berhenti pada epoch ke-42 akibat mekanisme EarlyStopping dengan training accuracy sebesar 65,41% lebih rendah dibandingkan validation accuracy sebesar 70,19%, sehingga mengindikasikan model belum mencapai konvergensi yang optimal.

Run 3 menghasilkan keseimbangan terbaik antara kemampuan pembelajaran dan generalisasi model. Selisih antara training accuracy sebesar 97,77% dan validation accuracy sebesar 85,37% adalah 12,40%. Pada penelitian ini, selisih tersebut diinterpretasikan sebagai gejala overfitting ringan, karena meskipun terdapat gap sebesar 12,40%, model tetap mampu mencapai test accuracy sebesar 85,36% dan validation loss terendah dibandingkan dua run lainnya. Hal ini menunjukkan bahwa model masih mampu melakukan generalisasi terhadap data yang belum pernah dilihat. Menurut Goodfellow et al. (2016), overfitting tidak hanya dinilai dari besarnya perbedaan performa antara data pelatihan dan validasi, tetapi juga dari kemampuan model mempertahankan performanya pada data baru. Selain itu, penerapan Dropout, L2 Regularization, Label Smoothing, dan EarlyStopping membantu mengurangi kecenderungan overfitting selama proses pelatihan (Géron,

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

2022). Oleh karena itu, Run 3 dipilih sebagai model terbaik dan digunakan pada tahap evaluasi.

4.4 Hasil Evaluasi Model

Model terbaik (Run 3, seed 999) dievaluasi menggunakan testing data sebanyak 33 video yang tidak pernah dilihat model selama pelatihan. Hasil evaluasi disajikan pada Tabel 4.5.

Tabel 4. 5 Hasil Evaluasi Model

Metrik	Nilai
<i>Accuracy</i>	85.36%
<i>Precision</i>	85.13%
<i>Recall</i>	84.85%
<i>F1-Score</i>	84.98%
ROC-AUC	0.8992
Video Accuracy	84,85%

Hasil evaluasi menunjukkan bahwa model BiGRU berhasil mencapai *accuracy* sebesar 85.36%, melampaui target minimum yang ditetapkan sebesar 80%. Nilai ROC-AUC sebesar 0.8992 menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan gerakan push-up yang benar dan salah. Nilai *precision* sebesar 85.13% menunjukkan bahwa dari seluruh prediksi benar yang dihasilkan model, 85.13% memang benar-benar gerakan yang benar. Nilai *recall* sebesar 84.85% menunjukkan bahwa model mampu mendeteksi 84.85% dari seluruh gerakan push-up yang benar secara keseluruhan. *F1-Score* sebesar 84.98% mencerminkan keseimbangan yang baik antara *precision* dan *recall*.

4.4.1 Confusion Matrix

Hasil *confusion matrix* model BiGRU pada data pengujian (*testing data*) ditunjukkan pada Gambar 4.8. Perhitungan *confusion matrix* dilakukan berdasarkan

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 menggunakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

jumlah segmen hasil pemotongan *sliding window*, bukan berdasarkan jumlah video secara utuh. Setiap video pada data pengujian dipotong menjadi beberapa sekuens dengan panjang 30 *frame* menggunakan metode *sliding window* tanpa *overlap* (*stride* 30). Dengan demikian, satu video dengan jumlah *frame* sebanyak N akan menghasilkan jumlah sekuens sesuai dengan panjang video yang tersedia.

Sebagai contoh, video dengan panjang 180 *frame* menghasilkan 6 sekuens, sedangkan video dengan panjang 300 *frame* menghasilkan 10 sekuens. Berdasarkan seluruh video pengujian, total sekuens yang dihasilkan dari 33 video adalah 239 segmen data. Setiap segmen tersebut kemudian diklasifikasikan secara independen oleh model BiGRU. Oleh karena itu, jumlah keseluruhan nilai pada *confusion matrix* ($83 + 19 + 16 + 121 = 239$) berbeda dengan jumlah keseluruhan video dalam dataset (220 video).



Gambar 4. 1 *Confusion Matrix*

Berdasarkan Gambar 4.8, model berhasil mengklasifikasikan 83 segmen gerakan salah dengan benar (*True Negative*) dan 121 segmen gerakan benar dengan benar (*True Positive*). Selain itu, terdapat 19 kesalahan *False Positive*, yaitu ketika segmen gerakan salah diprediksi sebagai gerakan benar, serta 16 kesalahan *False Negative*, yaitu ketika segmen gerakan benar diprediksi sebagai gerakan salah. Jumlah kesalahan klasifikasi yang relatif kecil menunjukkan bahwa model memiliki kemampuan yang cukup baik dan seimbang dalam membedakan kedua kelas gerakan.

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

4.5 Hasil Pengembangan Aplikasi Android

Aplikasi KINETIC merupakan aplikasi Android yang dikembangkan menggunakan bahasa pemrograman Kotlin dengan *framework* Jetpack Compose. Aplikasi ini dirancang untuk membantu pengguna mengevaluasi kualitas gerakan *push-up* secara otomatis dan *real-time* menggunakan model *deep learning* BiGRU yang telah dilatih dan dikonversi ke dalam format TensorFlow Lite. Visualisasi *skeleton* diimplementasikan menggunakan Compose Canvas dengan metode `drawLine()` dan `drawCircle()` secara manual tanpa memanfaatkan *library* pihak ketiga. Dengan pendekatan tersebut, garis tulang (*bones*) ditampilkan menggunakan warna cyan dan titik sendi (*joints*) menggunakan warna kuning secara *real-time* di atas tampilan pratinjau kamera.

Aplikasi KINETIC terdiri atas empat halaman utama yang saling terhubung dalam satu alur penggunaan, yaitu HomeScreen, PushUpGuideScreen, PushUpTutorialScreen, dan PushUpCameraScreen. Alur penggunaan aplikasi dimulai dari halaman utama, kemudian dilanjutkan ke halaman panduan, halaman tutorial, hingga halaman kamera yang menjadi bagian utama dalam proses evaluasi gerakan.


4.5.1 Halaman Utama (HomeScreen)

Halaman utama merupakan tampilan awal aplikasi yang digunakan sebagai navigasi utama bagi pengguna untuk memilih jenis latihan yang tersedia. Tampilan halaman utama aplikasi ditunjukkan pada Gambar 4.1



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan 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. 2 Halaman Utama


Halaman utama menampilkan tiga kartu menu latihan yang tersedia, yaitu Squat, *Push-Up*, dan Plank. Pengguna dapat memilih jenis latihan yang ingin dilakukan dengan mengetuk kartu sesuai pilihan. Pada penelitian ini, pengembangan dan pengujian difokuskan pada fitur *Push-Up* sebagai fitur utama yang digunakan untuk melakukan evaluasi kualitas gerakan.

4.5.2 Halaman Panduan (*PushUpGuideScreen*)

Halaman panduan merupakan halaman yang memberikan informasi awal mengenai tahapan persiapan sebelum pengguna melakukan evaluasi gerakan *push-up*. Tampilan halaman panduan aplikasi ditunjukkan pada Gambar 4.2

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. 3 Halaman Panduan


Halaman panduan menampilkan empat langkah penggunaan fitur evaluasi *push-up* berbasis kecerdasan buatan (*Artificial Intelligence*). Halaman ini bertujuan untuk mempersiapkan pengguna sebelum melakukan sesi latihan, terutama dalam mengatur posisi kamera dan posisi tubuh agar sesuai dengan kebutuhan sistem deteksi pose.

4.5.3 Halaman Tutorial (*PushUpTutorialScreen*)

Halaman tutorial merupakan halaman yang menyediakan materi pembelajaran mengenai teknik gerakan *push-up* yang benar sebelum pengguna melakukan proses evaluasi. Tampilan halaman tutorial aplikasi ditunjukkan pada Gambar 4.3

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. 4 Halaman Instruksi Push Up

Halaman tutorial menampilkan video referensi gerakan *push-up* yang benar, serta dilengkapi dengan enam instruksi teknik *push-up* dan lima kesalahan umum yang sering terjadi saat melakukan gerakan. Pengguna dapat memutar video dalam mode layar penuh (*fullscreen*) untuk mempelajari teknik yang tepat sebelum memulai sesi evaluasi.

4.5.4 Halaman Kamera (*PushUpCameraScreen*)

Halaman kamera merupakan komponen utama dalam aplikasi KINETIC yang digunakan untuk melakukan proses deteksi dan evaluasi gerakan *push-up* secara langsung. Halaman ini memiliki tiga kondisi (*state*) utama, yaitu IDLE, RECORDING, dan EVALUATION yang menggambarkan tahapan penggunaan fitur evaluasi gerakan.

4.5.4.1 State IDLE

State IDLE merupakan kondisi awal ketika pengguna memasuki halaman kamera sebelum memulai sesi evaluasi. Tampilan halaman kamera pada kondisi IDLE ditunjukkan pada 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. 5 Halaman Kamera(*Idle*)

Pada kondisi IDLE, aplikasi menampilkan *preview* kamera secara *real-time* beserta teks instruksi "Posisikan tubuh di depan kamera". Pengguna dapat mengganti kamera depan atau belakang menggunakan tombol *flip*, kemudian menekan tombol "MULAI GERAKAN" untuk memulai sesi evaluasi.

4.5.4.2 State RECORDING

State RECORDING merupakan kondisi ketika proses deteksi dan evaluasi gerakan *push-up* sedang berlangsung. Tampilan halaman kamera pada kondisi RECORDING ditunjukkan pada Gambar 4.5.



Gambar 4. 6 Sesi Mulai Gerakan(Record)

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

Pada kondisi RECORDING, aplikasi secara aktif mendeteksi dan mengevaluasi gerakan *push-up* pengguna. *Skeleton overlay* dengan garis berwarna cyan dan titik sendi berwarna kuning ditampilkan secara *real-time* di atas *preview* kamera. Informasi yang ditampilkan meliputi jumlah repetisi, penghitung GOOD dan BAD, tahap gerakan (*stage*) UP/DOWN, sudut siku, serta *progress bar*.

Hasil klasifikasi ditampilkan dalam bentuk *badge* pada bagian atas layar, yaitu "GOOD FORM" (hijau), "BAD FORM" (merah), "ANALYZING..." (biru), atau "TOO FAST" (oranye). Selain itu, umpan balik biomekanik spesifik juga ditampilkan secara *real-time*, seperti "Posisi tangan terlalu lebar", "Pinggang terlalu melengkung", "Turunkan badan lebih dalam", dan "Rapatkan siku ke tubuh". Sesi evaluasi dapat dihentikan secara manual dengan menekan tombol "STOP" atau berhenti secara otomatis setelah pengguna mencapai 10 repetisi.

4.5.4.3 State EVALUATION

State EVALUATION merupakan kondisi setelah sesi evaluasi selesai, ketika aplikasi menampilkan hasil analisis gerakan yang telah dilakukan pengguna. Tampilan hasil evaluasi ditunjukkan pada Gambar 4.6



Gambar 4. 7 Hasil Evaluasi

Setelah sesi selesai, aplikasi menampilkan ringkasan hasil evaluasi dengan judul "SESI SELESAI". Informasi yang ditampilkan meliputi total repetisi, jumlah gerakan GOOD dan BAD, persentase keberhasilan, serta ringkasan umpan balik biomekanik. Persentase keberhasilan ditampilkan menggunakan indikator warna hijau apabila nilai mencapai atau lebih dari 50%, sedangkan warna oranye digunakan apabila nilai berada di bawah 50%. Pengguna dapat memilih beberapa tindakan lanjutan, yaitu menyimpan sesi, mengulang sesi, atau keluar dari halaman evaluasi.

4.6 Hasil Pengujian Black Box Testing

Pengujian *Black Box Testing* dilakukan untuk memverifikasi bahwa seluruh fungsi aplikasi KINETIC berjalan sesuai dengan spesifikasi yang telah ditentukan. Pengujian dilakukan berdasarkan alur penggunaan aplikasi, mulai dari navigasi antarhalaman, pengelolaan izin kamera, proses evaluasi gerakan pada halaman kamera, hingga tampilan hasil evaluasi.

Pengujian terdiri atas sembilan kelompok skenario, yaitu *Navigation Flow*, *Camera Permission*, *State IDLE*, *State RECORDING*, *State Evaluation Processing*, *State Evaluation Review*, *Guide Screen*, *Tutorial Screen*, dan *Edge Cases*. Rincian setiap skenario pengujian, langkah pengujian, hasil yang diharapkan, serta status pengujian disajikan secara lengkap pada Lampiran 5 sampai dengan Lampiran 13.

Berdasarkan hasil *Black Box Testing*, seluruh 56 *test case* yang diujikan menunjukkan hasil sesuai dengan *expected result* yang telah ditentukan. Seluruh fungsi utama aplikasi KINETIC, seperti perpindahan halaman, pengelolaan izin kamera, proses deteksi dan evaluasi gerakan, perhitungan repetisi, pemberian umpan balik teknik, tampilan hasil evaluasi, serta penyimpanan sesi dapat berjalan dengan baik. Dengan demikian, aplikasi KINETIC telah memenuhi kebutuhan fungsional berdasarkan rancangan sistem yang telah dibuat.

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

4.7 Hasil User Acceptance Testing (UAT)

Pengujian *User Acceptance Testing* (UAT) dilakukan untuk mengetahui tingkat penerimaan pengguna terhadap aplikasi KINETIC. Pengujian ini melibatkan responden pengguna umum dengan rentang usia 16–25 tahun yang memiliki latar belakang frekuensi latihan *push-up* yang beragam. Pemilihan responden dilakukan menggunakan teknik *convenience sampling*, yaitu pemilihan partisipan berdasarkan kemudahan akses dan kesediaan untuk berpartisipasi, dengan kriteria pengguna telepon pintar Android serta pernah melakukan gerakan *push-up*.

Penentuan jumlah responden pada pengujian UAT mengacu pada metode Creswell (1998) yang menyatakan bahwa jumlah responden dalam penelitian *usability* berkisar antara 5 hingga 25 orang (Alam & Kurniasih, 2024). Berdasarkan acuan tersebut, penelitian ini melibatkan 12 responden yang memenuhi batas minimum jumlah responden dan dinilai cukup untuk memperoleh gambaran awal mengenai tingkat penerimaan pengguna terhadap aplikasi KINETIC.

Setiap responden diminta untuk mencoba aplikasi KINETIC secara langsung, kemudian mengisi kuesioner yang terdiri atas 16 pernyataan menggunakan skala penilaian 1–5. Rekapitulasi hasil pengisian kuesioner UAT disajikan pada Tabel 4.15.

Tabel 4. 6 Rekapitulasi Hasil UAT

No	Pernyataan	Rata-rata
1	Aplikasi mudah digunakan tanpa panduan	3.80
2	Tampilan antarmuka jelas dan mudah dipahami	4.10
3	Proses memulai sesi <i>push-up</i> mudah dilakukan	4.20
4	Hasil evaluasi ditampilkan dengan jelas	4.20
5	Aplikasi berhasil mendeteksi gerakan <i>push-up</i>	4.10
6	Penghitungan repetisi <i>push-up</i> akurat	3.90
7	Deteksi postur tubuh berjalan dengan baik	4.20

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

No	Pernyataan	Rata-rata
8	Feedback kecepatan gerakan sudah sesuai	4.30
9	Aplikasi berjalan lancar tanpa lag	4.20
10	Aplikasi membantu latihan push-up mandiri	4.00
11	Feedback membantu memperbaiki gerakan	4.20
12	Aplikasi berguna mencegah cedera	4.60
13	Dapat menggantikan pelatih untuk latihan dasar	3.90
14	Puas dengan performa aplikasi secara keseluruhan	4.40
15	Akan menggunakan untuk latihan rutin	3.70
16	Akan merekomendasikan ke orang lain	4.30
Rata-rata Keseluruhan		4.13

Berdasarkan Tabel 4.15, hasil pengujian UAT menunjukkan nilai rata-rata keseluruhan sebesar 4,13 dari skala 5 atau setara dengan 82,6%. Nilai tersebut termasuk dalam kategori Baik dan menunjukkan bahwa aplikasi KINETIC dapat diterima oleh pengguna.

Nilai rata-rata tertinggi diperoleh pada pernyataan mengenai kegunaan aplikasi dalam membantu mencegah cedera, yaitu sebesar 4,60, serta kepuasan terhadap performa aplikasi secara keseluruhan sebesar 4,40. Hasil tersebut menunjukkan bahwa pengguna menilai aplikasi memiliki manfaat dalam membantu melakukan latihan *push-up* secara lebih aman dan mandiri. Sementara itu, nilai rata-rata terendah diperoleh pada pernyataan mengenai penggunaan aplikasi untuk latihan rutin sebesar 3,70 dan kemudahan penggunaan tanpa panduan sebesar 3,80. Hal tersebut menunjukkan bahwa masih terdapat aspek yang dapat dikembangkan, terutama pada bagian panduan awal penggunaan dan peningkatan keterlibatan pengguna.

Berdasarkan masukan dari responden, beberapa kelebihan aplikasi yang berhasil diidentifikasi meliputi kemudahan penggunaan untuk latihan mandiri, kemampuan deteksi gerakan yang cukup baik, serta tampilan antarmuka yang menarik. Adapun beberapa aspek yang masih perlu diperbaiki antara lain responsivitas aplikasi pada

beberapa ukuran layar, penambahan fitur pendukung seperti riwayat sesi latihan, serta peningkatan akurasi deteksi pada kondisi pencahayaan yang kurang optimal.

4.8 Pembahasan

Penelitian ini berhasil mengembangkan aplikasi KINETIC yang mampu mengevaluasi kualitas gerakan *push-up* secara otomatis dan *real-time* menggunakan model BiGRU. Model yang dikembangkan memperoleh nilai *accuracy* sebesar 85,36% dan *ROC-AUC* sebesar 0,8992, sehingga melampaui target minimum akurasi sebesar 80% yang telah ditetapkan. Hasil tersebut menunjukkan bahwa pendekatan berbasis *pose estimation* menggunakan MoveNet dan klasifikasi sekuensial menggunakan BiGRU memiliki kemampuan yang baik dalam melakukan evaluasi kualitas gerakan *push-up*.

Dibandingkan dengan penelitian terdahulu, model yang dikembangkan dalam penelitian ini memiliki keunggulan pada aspek integrasi ke aplikasi Android secara *real-time* serta penggunaan fitur sekuensial berbasis waktu yang lebih mampu merepresentasikan dinamika gerakan dibandingkan pendekatan berbasis satu *frame*. Andriawan et al. (2025) memperoleh akurasi sebesar 95% menggunakan Random Forest, namun pendekatan tersebut tidak secara khusus mempertimbangkan hubungan temporal antarurutan gerakan dan belum diimplementasikan ke dalam aplikasi *mobile*. Sementara itu, penelitian ini menggunakan BiGRU yang mampu mempelajari pola temporal gerakan dari arah maju (*forward*) dan arah mundur (*backward*), sehingga lebih sesuai untuk permasalahan evaluasi gerakan yang memiliki karakteristik sekuensial.

Meskipun memberikan hasil yang baik, penelitian ini masih memiliki beberapa keterbatasan. Keterbatasan tersebut meliputi jumlah dataset yang masih terbatas, yaitu 220 video, penurunan performa deteksi pada kondisi pencahayaan yang kurang optimal atau ketika sebagian tubuh tidak terdeteksi oleh kamera, serta keterbatasan variasi sudut pengambilan gambar yang masih berfokus pada *front view* dan *side view*. Keterbatasan tersebut dapat menjadi pertimbangan untuk pengembangan penelitian selanjutnya, terutama melalui penambahan variasi data

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 peningkatan kemampuan model dalam menghadapi kondisi lingkungan yang lebih beragam.

© 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 V PENUTUP

5.1 Simpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penelitian ini berhasil mengembangkan aplikasi berbasis Android yang mampu melakukan evaluasi kualitas gerakan *push-up* secara otomatis dan *real-time* dengan memanfaatkan teknologi kecerdasan buatan. Aplikasi yang dikembangkan mengintegrasikan MoveNet untuk mendeteksi dan mengekstraksi 17 titik *keypoint* tubuh dari citra video yang diperoleh melalui kamera perangkat, kemudian data tersebut diproses menggunakan model BiGRU untuk mengenali pola gerakan secara sekuensial dan menghasilkan evaluasi terhadap kualitas gerakan *push-up*.

Berdasarkan hasil implementasi sistem, aplikasi KINETIC telah mampu menjalankan fungsi utama sesuai dengan rancangan yang telah dibuat. Sistem dapat melakukan proses pengambilan gambar melalui kamera, mendeteksi posisi tubuh pengguna, menghitung jumlah repetisi *push-up*, mengklasifikasikan gerakan benar dan salah, serta memberikan umpan balik terhadap beberapa kesalahan teknik, seperti posisi tangan terlalu lebar, siku terlalu melebar, posisi pinggang tidak netral, gerakan terlalu cepat, dan kedalaman gerakan yang kurang optimal. Selain itu, aplikasi juga mampu menampilkan hasil evaluasi serta menyimpan data sesi latihan pengguna.

Hasil pengujian fungsional menggunakan metode *Black Box Testing* menunjukkan bahwa seluruh fitur aplikasi berjalan sesuai dengan hasil yang diharapkan. Pengujian dilakukan terhadap berbagai fungsi utama, meliputi navigasi antarhalaman, pengelolaan izin kamera, proses evaluasi gerakan, pemberian umpan balik, penyimpanan sesi latihan, serta penanganan kondisi tertentu saat penggunaan aplikasi. Seluruh skenario pengujian memperoleh status berhasil sehingga menunjukkan bahwa aplikasi telah memenuhi kebutuhan fungsional yang telah dirancang.

Berdasarkan hasil evaluasi model, BiGRU memperoleh nilai *accuracy* sebesar 85,36%, *precision* sebesar 85,13%, *recall* sebesar 84,85%, *F1-score* sebesar 84,98%, dan nilai *ROC-AUC* sebesar 0,8992 pada data pengujian. Hasil tersebut melampaui target minimum akurasi sebesar 80%. Berdasarkan *confusion matrix*, model menghasilkan 83 *true negative*, 121 *true positive*, 19 *false positive*, dan 16 *false negative*. Hasil ini menunjukkan bahwa kombinasi MoveNet sebagai metode ekstraksi *keypoint* dan BiGRU sebagai model klasifikasi sekuensial mampu memberikan performa yang baik dalam melakukan evaluasi kualitas gerakan *push-up*.

Hasil pengujian penerimaan pengguna menggunakan metode *User Acceptance Testing* (UAT) menunjukkan nilai rata-rata sebesar 4,13 dari skala 1 sampai 5 atau setara dengan 82,6%. Nilai tersebut menunjukkan bahwa aplikasi memperoleh penilaian yang baik dari pengguna berdasarkan aspek kemudahan penggunaan, tampilan antarmuka, performa sistem, manfaat aplikasi, serta kualitas umpan balik yang diberikan. Dengan demikian, aplikasi KINETIC dapat diterima sebagai media pendukung latihan *push-up* secara mandiri.

Secara keseluruhan, penelitian ini menunjukkan bahwa penerapan kecerdasan buatan melalui kombinasi MoveNet dan BiGRU pada platform Android mampu mendukung proses evaluasi gerakan *push-up* secara otomatis dan *real-time*. Aplikasi yang dikembangkan tidak hanya mampu menghitung repetisi latihan, tetapi juga memberikan informasi mengenai kualitas gerakan dan kesalahan teknik yang dilakukan pengguna. Dengan demikian, tujuan penelitian untuk mengembangkan aplikasi evaluasi gerakan *push-up* berbasis kecerdasan buatan telah tercapai sesuai dengan ruang lingkup penelitian yang telah ditetapkan.

5.2 Saran

Berdasarkan hasil penelitian dan pengembangan aplikasi yang telah dilakukan, masih terdapat beberapa aspek yang dapat dikembangkan lebih lanjut untuk meningkatkan kualitas sistem dan memperluas manfaat aplikasi. Pengembangan pertama yang dapat dilakukan adalah meningkatkan jumlah serta variasi data 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

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

digunakan dalam proses pelatihan model kecerdasan buatan. Penambahan data dengan karakteristik pengguna yang lebih beragam, seperti variasi usia, jenis kelamin, bentuk tubuh, sudut pengambilan gambar, kondisi pencahayaan, dan latar belakang lingkungan, diharapkan dapat meningkatkan kemampuan generalisasi model sehingga performa sistem menjadi lebih stabil pada berbagai kondisi penggunaan.

Selain peningkatan kualitas dataset, penelitian selanjutnya dapat mengembangkan kemampuan aplikasi dengan menambahkan dukungan terhadap berbagai jenis latihan fisik lainnya, seperti *squat*, *sit-up*, *plank*, *pull-up*, maupun gerakan olahraga lainnya. Dengan penambahan variasi latihan, aplikasi dapat dikembangkan menjadi platform pendukung kebugaran yang lebih komprehensif dan mampu memberikan manfaat kepada lebih banyak pengguna.

Pengembangan fitur aplikasi juga dapat dilakukan melalui penambahan fitur pendukung, seperti riwayat latihan, target latihan harian atau mingguan, visualisasi perkembangan performa pengguna, sistem rekomendasi latihan, serta personalisasi program latihan berdasarkan kemampuan pengguna. Fitur-fitur tersebut diharapkan dapat meningkatkan keterlibatan pengguna dalam melakukan latihan secara rutin serta memberikan pengalaman penggunaan yang lebih baik.

Dari sisi teknologi kecerdasan buatan, penelitian selanjutnya dapat melakukan evaluasi perbandingan antara model Gated Recurrent Unit (GRU) dengan metode *deep learning* lainnya, seperti Long Short-Term Memory (LSTM), Bidirectional GRU (BiGRU), maupun arsitektur berbasis *Transformer*. Perbandingan tersebut dapat memberikan gambaran mengenai metode yang memiliki keseimbangan terbaik antara akurasi, efisiensi komputasi, dan kemampuan generalisasi dalam melakukan evaluasi gerakan *push-up* berbasis data *keypoint* tubuh.

Secara keseluruhan, penelitian ini diharapkan dapat menjadi referensi dalam pengembangan aplikasi olahraga berbasis kecerdasan buatan, khususnya pada bidang analisis gerakan manusia menggunakan teknologi *computer vision* dan *deep*



© Hak Cipta milik Politeknik Negeri Jakarta

learning. Melalui pengembangan lebih lanjut pada aspek kualitas model, fitur aplikasi, serta variasi latihan yang didukung, sistem yang dikembangkan diharapkan dapat memberikan manfaat yang lebih luas sebagai media pendukung latihan kebugaran secara mandiri dan interaktif.



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 PUSTAKA

- Suraju, G., Sahertian, J., Irawan, R.H., 2025. Inotek 9, 512.
- Pamungkas Putra, D., Kasih, P., Andriawan, R., 2025. Inotek 9, 1723–1732.
- Hmo, H., Confirmed, P.H.X., Osuna, E., Guadalupe, I., 2017. 1–2.
- Fisher, J., Steele, J., Wolf, M., Androulakis Korakakis, P., Smith, D., Giessing, J., 2022. Int. J. Strength Cond. 2, 1–21.
- Ullah, K., Shakir, D., Abid, U., Alahmari, S., Aslam, S., Ullah, Z., 2025. IET Gener. Transm. Distrib. 19.
- Jalili, A., Pan, F., Chen, A.X., Draayer, J.P., 2025. Phys. Rev. C 112, 1–16.
- Chen, H., Liu, Z., Cheng, X., Li, C., 2025.
- Muzakir, A., 2016.
- Moran, A., Gebka, B., Goldshteyn, J., Beyer, A., Johnson, N., Neuwirth, A., 2022.
- Mohsen, S., 2023. Multimed. Tools Appl. 82, 47733–47749.
- Tharatipyakul, A., Srikaewsiew, T., Pongnumkul, S., 2024. Heliyon 10, e36589.
- Boto, J., Correia, F.B., Borges, A.R., 2024. Procedia Comput. Sci. 239, 651–658.
- Cruz-Cunha, M.M., Domingos, D., Peres, E., Rijo, R., 2024. Procedia Comput. Sci. 239, 1–2.
- Cruz-cunha, M.M., Domingos, D., Peres, E., Santos, S.B.M.G., Kirikkayis, Y., Gallik, F., Winter, M., Marvan, P., Vitkova, E., Kocourkova, G., Sampaio, A.Z., Gomes, N., Cusumano, L., Rempling, R., Olsson, N., Jockwer, R., 2024. 239.
- Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., Zitnick, C.L., 2014. Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics) 8693 LNCS, 740–755.
- Yang, J., Zeng, A., Li, F., Liu, S., Zhang, R., Zhang, L., 2023. Proc. IEEE Int. Conf. Comput. Vis. 15076–15086.
- Yang, J., Zeng, A., Zhang, R., Zhang, L., 2025. Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics) 15104 LNCS, 249–268.

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

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
- Citra, P., Latihan Mandiri, P., Suraju, G., Sahertian, J., Irawan, R.H., 2025. Analisis Sistem Deteksi Gerakan Push-up Berbasis, INOTEK.
- Mahdi, E., Martin-Barreiro, C., Cabezas, X., 2025. Mathematics 13, 1–19.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., Inman, D.J., 2021. Mech. Syst. Signal Process. 151, 107398.
- He, J.L., Wang, J.H., Lo, C.M., Jiang, Z., 2025. Sensors 25.
- Muhamad Fahmi, H., Nur Luthfiatus, S., Tuliss Bial, F., Apriantono, T., Nia Sri, R., Yudhi Teguh, P., Awang, F., 2024. Retos 59, 349–354.
- Dyansyah, K.R.K., Purwantoro, S.D., Ilmi, M., Wulanningrum, R., 2025. Stain. (Seminar Nas. Teknol. dan Sains) 4, 199–207.
- Contreras-Salazar, K., Costa-Mondragon, P., Ugarte, W., 2025. Int. Conf. Inf. Commun. Technol. Ageing Well e-Health, ICT4AWE - Proc. 360–367.
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., Grundmann, M., 2020.
- Ataullah, W.H., Insan, I.M., Rahman, S.F., 2025. Int. J. Inf. Commun. Technol. 11, 118–135.
- Ertam, F., 2017. 2nd Int. Conf. Comput. Sci. Eng. UBMK 2017 755–758.
- Pattanayak, S., 2023. Pro Deep Learning with TensorFlow 2.0, Pro Deep Learning with TensorFlow 2.0.
- Rivas, F., Sierra-Garcia, J.E., Camara, J.M., 2025. Electron. 14, 0–33.
- Kim, T.Y., Yun, H.S., Yoon, H.M., Lee, S.J., 2025. Appl. Sci. 15.
- Luo, Y., Han, Y., Song, F., Xue, B., Yin, Y., 2025. Eng 6.
- Chen, C., Xue, L., Xing, W., 2023. Appl. Sci. 13.
- Shan, G., 2022. BMC Med. Inform. Decis. Mak. 22, 1–15.
- Mallinar, N., Simon, J.B., Abedsoltan, A., Pandit, P., Belkin, M., Nakkiran, P., 2022. Adv. Neural Inf. Process. Syst. 35.
- Tengah, S., Uts, S., Kuliah, M., 2024. 2015.
- Jo, B.J., Kim, S.K., 2022. Trait. du Signal 39, 119–124.



© 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

Hamilton, R.I., Glavcheva-Laleva, Z., Haque Milon, M.I., Anil, Y., Williams, J., Bishop, P., Holt, C., 2024. J. Bodyw. Mov. Ther. 40, 315–319.

Guan, S., Lu, H., Zhu, L., Fang, G., 2022. Neurocomputing 514, 256–267.

Alam, R.G., Puji Rahayu Kurniasih, 2024. JSAI (Journal Sci. Appl. Informatics) 7, 189–197.





DAFTAR RIWAYAT HIDUP PENULIS



Penulis Bernama Muhammad Rajiful Haq Gea, Lahir dan Besar Di Bekasi Sejak 6 Mei 2004. Penulis Pernah Menimba Ilmu di SMA Negeri 6 Kota Bekasi (2019 – 2022) dan SMP Negeri 9 Bekasi (2016 – 2019) yang keduanya berletak Kota Bekasi, Jawa Barat. Penulis lalu melanjutkan pendidikannya Ke 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



LAMPIRAN

Lampiran 1 Dokumentasi Pertemuan dengan Trainer untuk Validasi Data

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



Lampiran 2 Hasil Dataset yang sudah di Validasi Oleh Trainer

No	Nama Video	Benar/Salah	Alasan
1	push up 1	Salah	Punggung terlalu melengkung kedepan
2	push up 2	Salah	Tumpuan seharusnya ada di seluruh telapak tangan
3	push up 3	Benar	Setiap gerakan dilakukan dengan benar
4	push up 4	Salah	Posisi pinggang terlalu melengkung, posisi bokong terlalu tinggi
5	push up 5	Salah	Posisi tangan menggunakan jari, tidak aman untuk pemula
6	push up 6	Benar	Posisi badan netral, tapi temponya terlalu cepat
7	push up 7	Salah	Sikut tidak ditekuk, hanya hip yg turun kebawah
8	push up 8	Benar	Posisi lengan cukup aman dan pinggul tidak jatuh kebawah
9	push up 9	Benar	Posisi hip sudah sejajar lurus dengan bahu dan kaki, tangan sudah dibawah bahu
10	push up 10	Benar	
11	push up 11	Benar	
12	push up 12	Benar	
13	push up 13	Salah	Saat dorong keatas tidak seharusnya menghentak, apalagi sikut hipereksten
14	push up 14	Benar	
15	push up 15	Salah	Pinggang di tekuk
16	push up 16	Salah	Bukan gerakan push up
17	push up 17	Benar	
18	push up 18	Salah	Pinggul menekuk
19	push up 19	Benar	
20	push up 20	Salah	Badan tidak lurus, core tidak mengunci
21	push up 21	Benar	
22	push up 22	Salah	Pinggang terlalu melengkung, core kurang mengunci
23	push up 23	Salah	Badan tidak lurus, core tidak mengunci
24	push up 24	Benar	
25	push up 25	Benar	
26	push up 26	salah	Tidak sampai bawah, hanya kepalanya yg banyak turun
27	push up 27	Salah	Dada kurang turun kebawah, sikut kurang menekuk
28	push up 28	Benar	Tapi pinggang terlalu melengkung
29	push up 29	Benar	
30	push up 30	Benar	
31	push up 31	Salah	gerakan asal
32	push up 32	Benar	
33	push up 33	Salah	Banyak kompensasi, badan terlalu melengkung
34	push up 34	Benar	
35	push up 35	Benar	
36	push up 36	Benar	

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

Lampiran 3 Rekapitulasi Hasil Kuesioner Pengguna Aplikasi KINETIC




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



© Hak Cipta milik Politeknik Negeri Jakarta


Lampiran 4 Dokumentasi Bimbingan Dengan Bu Mera Kartika Delimayanti, S.Si., M.T., Ph.D

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



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

Lampiran 5 Hasil Black Box Testing — Navigation Flow

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
1.1	Menu Home ke Panduan	Tekan tombol "MULAI EVALUASI"	Halaman panduan AI ditampilkan	Berhasil
1.2	Panduan ke Tutorial	Tekan tombol "MENGETI, AYO LATIHAN"	Halaman tutorial ditampilkan	Berhasil
1.3	Tutorial ke Kamera	Tekan tombol "OKE, MENGETI"	Halaman kamera ditampilkan	Berhasil
1.4	Simpan Sesi	Tekan tombol "Simpan Sesi"	Data sesi tersimpan dan kembali ke Home	Berhasil
1.5	Keluar Sesi	Tekan tombol "Keluar"	Kembali ke halaman sebelumnya	Berhasil
1.6	Kembali dari Panduan	Tekan tombol kembali	Kembali ke Home	Berhasil

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

Lampiran 6 Hasil Black Box Testing — Camera Permission

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
2.1	Izin Kamera Diberikan	Izinkan akses kamera	Kamera aktif dan siap digunakan	Berhasil
2.2	Izin Kamera Ditolak	Tolak akses kamera	Halaman permintaan izin ditampilkan	Berhasil
2.3	Permintaan Izin Ulang	Tekan tombol izin kamera	Dialog izin muncul kembali	Berhasil
2.4	Penolakan Permanen	Tolak izin dua kali	Halaman permintaan izin tetap ditampilkan	Berhasil

Lampiran 7 Hasil Black Box Testing — State IDLE

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
3.1	Tampilan Kamera	Buka halaman kamera	Tampilan kamera muncul	Berhasil
3.2	Teks Instruksi	Lihat layar	Instruksi penggunaan ditampilkan	Berhasil
3.3	Pergantian Kamera	Tekan tombol flip	Kamera berganti	Berhasil
3.4	Mulai Gerakan	Tekan tombol "MULAI GERAKAN"	Sistem memulai proses evaluasi	Berhasil

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.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
3.5	Tombol Kembali	Tekan tombol kembali	Kembali ke halaman tutorial	Berhasil

Lampiran 8 Hasil Black Box Testing – State Recording

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
4.1	Progress Bar	Lakukan push-up	Progress bar bertambah	Berhasil
4.2	Penghitung Repetisi	Lakukan satu push-up	Repetisi bertambah satu	Berhasil
4.3	Penghitung GOOD/BAD	Lakukan gerakan benar dan salah	Counter bertambah sesuai hasil deteksi	Berhasil
4.4	Indikator Tahap Gerakan	Lakukan gerakan naik dan turun	Status gerakan berubah sesuai posisi tubuh	Berhasil
4.5	Sudut Siku	Lakukan push-up	Sudut siku ditampilkan dan berubah	Berhasil
4.6	Feedback Gerakan Benar	Lakukan gerakan benar	Feedback GOOD FORM ditampilkan	Berhasil
4.7	Feedback Gerakan Salah	Lakukan gerakan salah	Feedback BAD FORM ditampilkan	Berhasil

© 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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
4.8	Feedback Terlalu Cepat	Lakukan gerakan cepat	Feedback TOO FAST ditampilkan	Berhasil
4.9	Feedback Analisis	Sistem menganalisis gerakan	Status ANALYZING ditampilkan	Berhasil
4.10	Feedback Posisi Tangan	Tangan terlalu lebar	Pesan koreksi ditampilkan	Berhasil
4.11	Feedback Posisi Pinggang	Pinggang melengkung	Pesan koreksi ditampilkan	Berhasil
4.12	Feedback Kedalaman	Push-up kurang dalam	Pesan koreksi ditampilkan	Berhasil
4.13	Feedback Posisi Siku	Siku terlalu melebar	Pesan koreksi ditampilkan	Berhasil
4.14	Skeleton Tubuh	Lakukan gerakan	Skeleton tubuh ditampilkan	Berhasil
4.15	Penghitung Frame	Jalankan evaluasi	Jumlah frame bertambah	Berhasil
4.16	Tombol Stop	Tekan STOP	Proses evaluasi dihentikan	Berhasil
4.17	Berhenti Otomatis	Capai 10 repetisi	Sistem berhenti otomatis	Berhasil
4.18	Tombol Kembali	Tekan tombol kembali	Tidak ada respons selama evaluasi	Berhasil

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

Lampiran 9 Hasil Black Box Testing – State Evaluation Processing

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
5.1	Tampilan Pemrosesan	Selesaikan sesi	Indikator pemrosesan ditampilkan	Berhasil
5.2	Durasi Pemrosesan	Tunggu proses	Halaman hasil evaluasi ditampilkan	Berhasil

Lampiran 10 Hasil Black Box Testing – State Evaluation Review

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
6.1	Judul Halaman	Lihat layar	Judul sesi selesai ditampilkan	Berhasil
6.2	Tidak Ada Repetisi	Repetisi = 0	Pesan tidak ada repetisi ditampilkan	Berhasil
6.3	Evaluasi Baik	GOOD $\geq$ BAD	Pesan sesi baik ditampilkan	Berhasil
6.4	Evaluasi Kurang Baik	BAD > GOOD	Pesan perbaikan gerakan ditampilkan	Berhasil

© 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 mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
6.5	Persentase Tinggi	Success $\geq$ 50%	Persentase keberhasilan ditampilkan	Berhasil
6.6	Persentase Rendah	Success $<$ 50%	Persentase keberhasilan ditampilkan	Berhasil
6.7	Statistik Latihan	Ada repetisi	Statistik latihan ditampilkan	Berhasil
6.8	Ringkasan Feedback	Ada kesalahan	Ringkasan evaluasi ditampilkan	Berhasil
6.9	Simpan Sesi	Tekan simpan	Data tersimpan	Berhasil
6.10	Simpan Tanpa Repetisi	Simpan saat 0 repetisi	Data tidak disimpan	Berhasil
6.11	Simpan Ganda	Tekan dua kali	Data hanya tersimpan sekali	Berhasil
6.12	Loading Simpan	Tekan simpan	Indikator loading ditampilkan	Berhasil
6.13	Gagal Menyimpan	Simulasikan error	Pesan kesalahan ditampilkan	Berhasil
6.14	Ulang Sesi	Tekan ulang	Sesi baru dimulai	Berhasil

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.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
6.15	Keluar	Tekan keluar	Kembali ke halaman sebelumnya	Berhasil

Lampiran 11 Hasil Black Box Testing – Guide Screen

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
7.1	Judul Panduan	Lihat layar	Judul panduan AI ditampilkan	Berhasil
7.2	Langkah Panduan	Gulir halaman	Seluruh panduan ditampilkan	Berhasil

Lampiran 12 Hasil Black Box Testing – Tutorial Screen

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
8.1	Thumbnail Video	Lihat layar	Thumbnail video ditampilkan	Berhasil
8.2	Putar Video	Tekan thumbnail	Video diputar	Berhasil
8.3	Tutup Video	Tekan tombol tutup	Kembali ke tutorial	Berhasil

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

Lampiran 13 Hasil Black Box Testing – Edge Cases

No.	Test Case	Langkah Pengujian	Hasil yang Diharapkan	Status
9.1	Tubuh Tidak Terdeteksi	Tubuh keluar dari kamera	Sistem tidak menghitung repetisi	Berhasil
9.2	Gerakan Terlalu Cepat	Push-up sangat cepat	Feedback TOO FAST muncul	Berhasil
9.3	Push-up Kurang Dalam	Gerakan tidak mencapai kedalaman standar	Sistem memberikan koreksi	Berhasil
9.4	Posisi Tangan Salah	Tangan terlalu lebar	Sistem memberikan koreksi	Berhasil
9.5	Posisi Pinggang Salah	Pinggang melengkung	Sistem memberikan koreksi	Berhasil
9.6	Posisi Siku Salah	Siku terlalu melebar	Sistem memberikan koreksi	Berhasil
9.7	Target Repetisi Tercapai	Lakukan 10 repetisi	Sistem menghentikan sesi dan menampilkan hasil evaluasi	Berhasil