

Evaluasi 1D-CNN untuk Klasifikasi Gerakan Tolak Peluru Berbasis MediaPipe

^{1*}Alfina Putri Tursina, ²Made Ayu Dusea Widyadara, ³Daniel Swanjaya

¹²³ Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ^{*1}putrialfina113@gmail.com, ²madedara@gmail.com, ³daniel@unpkediri.ac.id

Penulis Korespondensi : Alfina Putri Tursina

Abstrak—Penelitian ini bertujuan untuk mengevaluasi kinerja model CNN satu dimensi dalam mengklasifikasikan kualitas gerakan tolak peluru berdasarkan landmark tubuh. Data yang digunakan berasal dari kategori Shotput pada dataset UCF101 yang diperoleh melalui Kaggle. Data terdiri dari 150 klip video yang dibagi ke dalam tiga fase gerakan, yaitu awalan, dorongan, dan sikap akhir, serta dua kategori kualitas gerakan, yaitu sempurna dan tidak sempurna. Tahapan penelitian meliputi preprocessing video menggunakan OpenCV, ekstraksi landmark tubuh menggunakan MediaPipe Pose, pelatihan model CNN satu dimensi, dan evaluasi model. Hasil ekstraksi menghasilkan dataset fitur berukuran $150 \times 30 \times 99$. Model memperoleh training accuracy sebesar 88,54%, validation accuracy sebesar 70,83%, dan accuracy pengujian sebesar 60%. Hasil evaluasi menunjukkan bahwa model mampu mengenali kedua kelas, meskipun masih terdapat kesalahan klasifikasi. Dengan demikian, pendekatan MediaPipe Pose dan 1D-CNN memiliki potensi untuk digunakan dalam klasifikasi gerakan tolak peluru, tetapi masih memerlukan peningkatan variasi data dan perbaikan model.

Kata Kunci—1D-CNN, gerakan tolak peluru, klasifikasi gerakan, MediaPipe Pose

Abstract—This study aims to evaluate the performance of a one-dimensional CNN model in classifying the quality of shot put movements based on body landmarks. The data were obtained from the Shotput category in the UCF101 dataset available on Kaggle. The dataset consisted of 150 video clips divided into three movement phases, namely initial phase, push phase, and final phase, as well as two movement quality categories, namely perfect and imperfect. The research stages included video preprocessing using OpenCV, body landmark extraction using MediaPipe Pose, one-dimensional CNN model training, and model evaluation. The extraction process produced a feature dataset with a size of $150 \times 30 \times 99$. The model achieved a training accuracy of 88.54%, a validation accuracy of 70.83%, and a testing accuracy of 60%. The evaluation results indicate that the model was able to recognize both classes, although several misclassifications still occurred. Therefore, the MediaPipe Pose and 1D-CNN approach has potential for shot put movement classification, but further improvement in data variation and model optimization is still required.

Keywords— 1D-CNN, MediaPipe Pose, movement classification, shot put

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



I. PENDAHULUAN

Tolak peluru merupakan salah satu nomor lempar dalam cabang olahraga atletik yang membutuhkan kekuatan, kecepatan, koordinasi, dan penguasaan teknik gerak. Dalam pelaksanaannya, tolak peluru memiliki beberapa gaya, yaitu gaya ortodoks, gaya O'Brien, serta gaya *spin* atau gaya berputar [1]. Gerakan tolak peluru tidak hanya bergantung pada kekuatan lengan, tetapi juga melibatkan koordinasi anggota tubuh secara menyeluruh. Koordinasi gerakan

yang tepat diperlukan agar tolakan dapat dilakukan secara efektif dan menghasilkan jarak yang optimal.

Penilaian teknik gerakan olahraga umumnya masih dilakukan melalui pengamatan langsung oleh pelatih atau guru. Cara tersebut memiliki keterbatasan karena hasil penilaian dapat dipengaruhi oleh ketelitian, pengalaman, dan sudut pandang pengamat. Penelitian biomekanika menunjukkan bahwa gerakan tolak peluru dapat dianalisis melalui tahap persiapan, meluncur, pelepasan, dan pemulihan [1]. Oleh karena itu, evaluasi gerakan memerlukan pendekatan yang lebih terukur dan berbasis data agar kesalahan teknik dapat diketahui secara lebih konsisten.

Perkembangan *computer vision* dan kecerdasan buatan memungkinkan gerakan tubuh manusia dianalisis secara otomatis melalui citra atau video. Salah satu pendekatan yang digunakan adalah *human pose estimation*, yaitu proses mendeteksi titik-titik tubuh manusia dan merepresentasikannya dalam bentuk koordinat. MediaPipe Pose dapat mendeteksi 33 *landmark* tubuh dalam bentuk koordinat tiga dimensi yang dapat digunakan sebagai fitur klasifikasi gerakan [2]. Selain itu, kumpulan *keypoints* dari urutan video juga dapat digunakan untuk mengenali pola gerakan olahraga secara otomatis [3].

Beberapa penelitian sebelumnya telah menerapkan MediaPipe dan algoritma klasifikasi dalam analisis gerakan olahraga. MediaPipe dikombinasikan dengan *Random Forest Classifier* untuk mengklasifikasikan *pose* pilates ke dalam kategori benar dan salah [2]. Pendekatan *Long Short-Term Memory* digunakan untuk mengenali gerakan olahraga berdasarkan urutan *keypoints* tubuh [3]. Kombinasi MediaPipe dan *Convolutional Neural Network* diterapkan untuk mengenali gerakan *stretching* pada olahraga futsal [4]. Sementara itu, *K-Nearest Neighbors* digunakan untuk mengklasifikasikan gerakan bulutangkis berdasarkan fitur gerakan tubuh [5].

MediaPipe Pose dan *1D-CNN* dipilih karena sesuai dengan karakteristik data yang digunakan dalam penelitian ini. MediaPipe Pose digunakan untuk mengubah gerakan pada video menjadi deret koordinat *landmark* tubuh. Selanjutnya, *1D-CNN* digunakan untuk mempelajari pola pada urutan koordinat dari beberapa *frame*, sehingga model tidak memproses citra mentah secara langsung. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi kinerja model *1D-CNN* dalam mengklasifikasikan gerakan tolak peluru ke dalam kategori “sempurna” dan “tidak sempurna” berdasarkan fitur *landmark* tubuh dari MediaPipe Pose.

II. METODE

Penelitian ini menggunakan pendekatan eksperimen komputasi untuk mengevaluasi kinerja model *1D-CNN* dalam mengklasifikasikan kualitas gerakan tolak peluru gaya spin. Tahapan penelitian dimulai dari pengumpulan data video, preprocessing data, ekstraksi landmark menggunakan MediaPipe Pose, pembentukan dataset fitur, pelatihan model *1D-CNN*, hingga evaluasi model. Alur metode penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur Metode Penelitian

Berdasarkan Gambar 1, proses penelitian diawali dengan pengumpulan data video gerakan tolak peluru yang dikelompokkan berdasarkan fase gerakan dan kategori kualitas gerakan. Data video kemudian melalui tahap preprocessing untuk menyesuaikan format dan mempersiapkan data sebelum diekstraksi. Setelah itu, setiap video diproses menggunakan MediaPipe Pose untuk

memperoleh landmark tubuh. Hasil ekstraksi landmark disusun menjadi dataset fitur yang digunakan sebagai masukan model 1D-CNN. Model yang telah dilatih kemudian dievaluasi menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix.

A. Pengumpulan Data Video

Data yang digunakan dalam penelitian ini berasal dari *dataset* publik UCF101 - *Action Recognition* pada platform Kaggle. Penelitian ini hanya menggunakan kategori *Shotput* karena sesuai dengan objek penelitian, yaitu gerakan tolak peluru. Video yang digunakan dipilih berdasarkan kualitas visual, kejelasan tubuh pelaku gerakan, sudut pengambilan gambar, dan kelengkapan rangkaian gerakan. Video yang terlalu gelap, buram, atau tidak menampilkan tubuh secara memadai tidak digunakan karena dapat memengaruhi proses deteksi *landmark* menggunakan MediaPipe Pose.

Setelah proses seleksi, setiap video dipotong ke dalam fase awalan, dorongan, dan sikap akhir. Setiap fase kemudian diberi label “sempurna” atau “tidak sempurna” berdasarkan posisi tubuh, keseimbangan, dan koordinasi gerakan. Pengelompokan kualitas gerakan ke dalam kategori benar dan salah juga diterapkan pada penelitian penilaian kualitas gerakan *push-up* [6]. Pendekatan klasifikasi gerakan benar dan salah juga digunakan dalam penelitian deteksi gerakan servis bulutangkis [7].

B. Preprocessing Data

Tahap *preprocessing* dilakukan untuk menyiapkan video sebelum proses ekstraksi *landmark*. Setiap klip dibaca menggunakan OpenCV, kemudian video diproses berdasarkan fase gerakan yang telah ditentukan. Proses tersebut menghasilkan urutan *frame* yang merepresentasikan perubahan posisi tubuh selama gerakan berlangsung. Penggunaan OpenCV dan MediaPipe untuk memproses urutan *frame* juga diterapkan pada pengenalan gerakan tangan untuk mengendalikan *slide* presentasi [8].

Durasi setiap klip video tidak selalu sama sehingga jumlah *frame* perlu diseragamkan. Pengambilan *frame* dilakukan secara merata dari awal hingga akhir klip agar seluruh bagian gerakan tetap terwakili. Setiap klip direpresentasikan menjadi 30 *frame* sehingga seluruh data memiliki panjang masukan yang sama. Pemrosesan urutan gerakan dari video juga diterapkan pada pembelajaran tari Remo menggunakan MediaPipe dan *Dynamic Time Warping* [9].

C. Ekstraksi Landmark MediaPipe Pose

Setiap *frame* hasil *preprocessing* diproses menggunakan MediaPipe Pose untuk mendeteksi titik-titik tubuh atlet. MediaPipe Pose menghasilkan 33 *landmark* yang merepresentasikan kepala, bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki. Setiap *landmark* terdiri dari koordinat x, y, dan z yang menunjukkan posisi tubuh dalam ruang tiga dimensi. Representasi *pose* tiga dimensi menggunakan MediaPipe juga diterapkan pada sistem latihan taekwondo [10].

Satu *frame* menghasilkan 99 fitur yang diperoleh dari 33 *landmark* dikalikan tiga koordinat. Karena setiap klip terdiri dari 30 *frame*, satu klip menghasilkan data berukuran 30×99 . Koordinat tersebut kemudian dinormalisasi dengan menjadikan titik tengah pinggul sebagai pusat tubuh dan jarak antara pusat bahu dengan pusat pinggul sebagai skala. Penggunaan koordinat *pose* sebagai dasar analisis posisi tubuh juga diterapkan pada penelitian evaluasi postur panahan [11].

D. Pelatihan Model 1D-CNN Berbasis Landmark MediaPipe

Data hasil ekstraksi *landmark* digunakan sebagai masukan model 1D-CNN dengan bentuk 30×99 pada setiap klip. Keseluruhan data dibagi menjadi data latih dan data uji dengan rasio 80:20. Pembagian dilakukan secara terstratifikasi berdasarkan kombinasi fase gerakan dan label kelas

agar setiap kelompok tetap terwakili. Dari 150 klip video, sebanyak 120 klip digunakan sebagai data latih dan 30 klip digunakan sebagai data uji.

Model *1D-CNN* dipilih karena data masukan berbentuk deret koordinat, bukan citra mentah. Arsitektur model terdiri dari lapisan *Conv1D*, *Batch Normalization*, *MaxPooling1D*, *Dropout*, *Global Average Pooling*, dan *Dense*. Pendekatan CNN-LSTM telah digunakan untuk mengklasifikasikan postur pada olahraga menembak [12]. CNN juga diterapkan pada pengenalan postur olahraga, yoga, dan tari [13], sedangkan kombinasi CNN-LSTM digunakan untuk menganalisis pola postur duduk secara berurutan [14].

E. Evaluasi Model

Evaluasi dilakukan menggunakan 30 klip data uji yang tidak digunakan pada proses pelatihan. Label hasil prediksi dibandingkan dengan label sebenarnya untuk mengetahui kemampuan model dalam mengenali data baru. Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Penggunaan metrik tersebut juga diterapkan pada penelitian evaluasi kebugaran fisik berbasis deteksi gerakan [15].

Accuracy digunakan untuk mengukur proporsi prediksi yang benar dari seluruh data uji. *Precision* menunjukkan ketepatan prediksi pada suatu kelas, sedangkan *recall* menunjukkan kemampuan model menemukan seluruh data pada kelas tersebut. *F1-score* digunakan untuk melihat keseimbangan antara *precision* dan *recall*. Sementara itu, *confusion matrix* digunakan untuk menampilkan distribusi prediksi benar dan salah pada setiap kelas.

Rumus evaluasi yang digunakan ditunjukkan pada Persamaan (1) sampai (4).

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

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

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

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

Keterangan dari rumus tersebut adalah *True Positive* (TP), yaitu data pada suatu kelas yang diprediksi benar oleh model. *True Negative* (TN) adalah data di luar kelas tersebut yang diprediksi benar sebagai bukan kelas tersebut. *False Positive* (FP) adalah data yang salah diprediksi masuk ke suatu kelas, sedangkan *False Negative* (FN) adalah data pada suatu kelas yang gagal dikenali oleh model. Selain metrik tersebut, *confusion matrix* digunakan untuk menampilkan jumlah prediksi benar dan salah pada masing-masing kelas, sehingga hasil klasifikasi dapat dianalisis lebih rinci.

III. HASIL DAN PEMBAHASAN

Pada bagian ini dijelaskan hasil dari setiap tahapan penelitian, mulai dari pengumpulan data, *preprocessing*, ekstraksi *landmark* tubuh, pelatihan model *1D-CNN*, hingga evaluasi model. Hasil tersebut digunakan untuk mengetahui proses pengolahan video gerakan tolak peluru menjadi data fitur berbasis *landmark* MediaPipe Pose serta melihat kemampuan model dalam mengklasifikasikan gerakan ke dalam kategori “sempurna” dan “tidak sempurna”.

A. Hasil Pengumpulan Data

Data yang digunakan pada penelitian ini diperoleh dari *dataset* publik UCF101 - Action Recognition pada platform Kaggle. Dari *dataset* tersebut, penelitian ini hanya menggunakan kategori Shotput karena sesuai dengan objek penelitian, yaitu gerakan tolak peluru. Data video kemudian diseleksi berdasarkan kejelasan tampilan tubuh, sudut pengambilan gambar, dan kelengkapan rangkaian gerakan.

Setelah proses seleksi, video dipotong berdasarkan tiga fase utama gerakan tolak peluru, yaitu fase awalan, fase dorongan, dan fase sikap akhir. Setiap fase dikelompokkan ke dalam dua kategori kualitas gerakan, yaitu “sempurna” dan “tidak sempurna”. Berdasarkan hasil pengumpulan dan pemotongan data, diperoleh sebanyak **150 klip video**, yang terdiri dari **75 klip gerakan sempurna** dan **75 klip gerakan tidak sempurna**.

Tabel 1. Jumlah Data Video Berdasarkan Fase dan Kategori

Fase Gerakan	Sempurna	Tidak Sempurna	Total
Awalan	25	25	50
Dorongan	25	25	50
Sikap Akhir	25	25	50
Total	75	75	150

Berdasarkan Tabel 1, jumlah data pada setiap fase dibuat seimbang antara kategori “sempurna” dan “tidak sempurna”. Setiap fase memiliki 25 klip untuk masing-masing kategori, sehingga total data pada setiap fase berjumlah 50 klip. Keseimbangan data ini diperlukan agar model memperoleh jumlah contoh yang sama pada setiap kelas dan tidak cenderung mempelajari salah satu kategori secara dominan. Data yang telah terkumpul kemudian digunakan pada tahap *preprocessing* sebelum dilakukan ekstraksi *landmark* menggunakan MediaPipe Pose.

B. Hasil Preprocessing Data

Tahap *preprocessing* dilakukan untuk menyiapkan data video agar memiliki bentuk yang seragam sebelum masuk ke proses ekstraksi *landmark*. Pada tahap ini, setiap klip video dibaca menggunakan OpenCV, kemudian *frame* diambil secara merata dari awal hingga akhir klip. Pengambilan *frame* secara merata dilakukan agar informasi gerakan pada setiap bagian video tetap terwakili. Hasil *preprocessing* kemudian dirangkum pada Tabel 2.

Berdasarkan hasil *preprocessing*, seluruh data sebanyak **150 klip video** berhasil diproses. Setiap klip video direpresentasikan menjadi **30 frame**, sehingga jumlah *frame* yang dihasilkan secara keseluruhan adalah **4.500 frame**. Penyeragaman jumlah *frame* ini diperlukan karena model *1D-CNN* membutuhkan bentuk *input* yang tetap pada setiap data.

Tabel 2. Hasil Preprocessing Data

Fase	Label	Jumlah Klip	Total Frame
Awalan	Sempurna	25	750
Awalan	Tidak Sempurna	25	750
Dorongan	Sempurna	25	750
Dorongan	Tidak Sempurna	25	750
Akhiran	Sempurna	25	750
Akhiran	Tidak Sempurna	25	750
Total		150	4.500

Berdasarkan Tabel 2, setiap fase dan kategori memiliki jumlah klip serta *frame* yang seimbang. Setiap kategori pada masing-masing fase terdiri dari 25 klip video dengan total 750

frame. Kondisi ini menunjukkan bahwa data hasil *preprocessing* telah siap digunakan pada tahap ekstraksi *landmark* tubuh menggunakan MediaPipe Pose.

C. Hasil Ekstraksi Landmark MediaPipe Pose

Setiap *frame* hasil *preprocessing* diproses menggunakan MediaPipe Pose untuk memperoleh titik-titik tubuh atlet. MediaPipe Pose menghasilkan 33 *landmark* yang mencakup bagian kepala, bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki. Setiap *landmark* terdiri dari koordinat x, y, dan z yang menggambarkan posisi tubuh. Koordinat tersebut kemudian disusun menjadi fitur numerik yang dapat diproses oleh model *1D-CNN*.

Satu *frame* menghasilkan 99 fitur yang diperoleh dari 33 *landmark* dikalikan tiga koordinat. Karena setiap klip direpresentasikan menjadi 30 *frame*, satu klip menghasilkan bentuk data berukuran 30×99 . Dengan jumlah keseluruhan sebanyak 150 klip, bentuk akhir *dataset* fitur adalah $150 \times 30 \times 99$. Rincian hasil ekstraksi *landmark* disajikan pada Tabel 3.

Tabel 3. Hasil Ekstraksi Landmark

Keterangan	Nilai
Jumlah klip video	150
Jumlah frame per klip	30
Jumlah landmark per frame	33
Jumlah koordinat per landmark	3
Jumlah fitur per frame	99
Bentuk dataset fitur	$150 \times 30 \times 99$

Berdasarkan Tabel 3, data video berhasil diubah menjadi deret fitur numerik yang merepresentasikan perubahan posisi tubuh selama gerakan berlangsung. Pemanfaatan *landmark* MediaPipe sebagai dasar pemantauan gerakan juga diterapkan pada sistem pelacakan latihan secara *real-time* [16]. Pada penelitian ini, penggunaan koordinat x, y, dan z memungkinkan model mempelajari pola gerakan tanpa memproses citra mentah secara langsung. Namun, kualitas fitur yang dihasilkan tetap dipengaruhi oleh kejelasan tubuh, sudut kamera, dan keberhasilan MediaPipe Pose dalam mendeteksi *landmark* pada setiap *frame*.

D. Hasil Pelatihan Model 1D-CNN

Pelatihan model dilakukan menggunakan *dataset* fitur berukuran $150 \times 30 \times 99$. Data tersebut dibagi menjadi data latih dan data uji menggunakan rasio 80:20. Berdasarkan pembagian tersebut, diperoleh 120 klip sebagai data latih dan 30 klip sebagai data uji. Pembagian dilakukan secara terstratifikasi agar setiap fase dan kategori gerakan tetap terwakili pada kedua kelompok data.

Model yang digunakan memiliki bentuk masukan 30×99 dan terdiri dari lapisan *Conv1D*, *Batch Normalization*, *MaxPooling1D*, *Dropout*, *Global Average Pooling*, serta *Dense*. Jumlah parameter keseluruhan pada model adalah **102.657 parameter**. Dari jumlah tersebut, sebanyak **102.017** merupakan parameter yang dapat dilatih dan **640** merupakan parameter yang tidak dilatih. Rincian pembagian data dan arsitektur model disajikan pada Tabel 4.

Tabel 4. Pembagian Data dan Arsitektur Model

Keterangan	Nilai
Jumlah seluruh data	150 klip
Data latih	120 klip
Data uji	30 klip
Bentuk input model	30×99
Total parameter	102.657
Trainable parameter	102.017
Non-trainable parameter	640


Proses pelatihan model menunjukkan bahwa nilai akurasi pada data latih mencapai **88,54%**, dengan nilai *loss* sebesar **0,2862**. Sementara itu, akurasi validasi yang diperoleh sebesar **70,83%**, dengan nilai *validation loss* sebesar **0,7271**. Hasil tersebut menunjukkan bahwa model mampu mempelajari pola gerakan dari data latih dan memperoleh performa validasi yang cukup baik. Namun, nilai *validation loss* yang masih lebih tinggi dibandingkan *training loss* menunjukkan bahwa model masih memiliki kesalahan dalam mengenali sebagian pola gerakan pada data validasi.

Tabel 5. Hasil Akhir Pelatihan Model


Metrik	Nilai
Training Accuracy	88,54%
Validation Accuracy	70,83%
Training Loss	0,2862
Validation Loss	0,7271

Pengolahan urutan koordinat tubuh juga telah digunakan untuk mengklasifikasikan gerakan Tai Chi menggunakan MediaPipe Pose dan LSTM [17]. MediaPipe Pose digunakan pula dalam sistem pencarian koreografi *hiphop* berdasarkan kemiripan posisi tubuh [18]. Pengenalan pola gerakan melalui MediaPipe dan OpenCV juga diterapkan untuk mengendalikan kursor pada presentasi [19]. Selain itu, koordinat pose tubuh digunakan untuk menghitung repetisi gerakan pada sistem evaluasi kebugaran [20]. Berbagai penerapan tersebut menunjukkan bahwa deret koordinat tubuh dapat digunakan sebagai representasi gerakan, meskipun jenis model dan tujuan klasifikasinya berbeda.

Grafik perubahan akurasi selama pelatihan ditunjukkan pada Gambar 2, sedangkan grafik perubahan *loss* ditunjukkan pada Gambar 3. Grafik akurasi memperlihatkan peningkatan kemampuan model dalam mengenali pola pada data latih. Sementara itu, perubahan nilai validasi menunjukkan bahwa kemampuan model dalam mengenali data baru belum sepenuhnya stabil. Perbedaan antara kurva pelatihan dan validasi mengindikasikan bahwa performa model masih dapat ditingkatkan melalui penambahan variasi data dan penyesuaian parameter.



Gambar 2. Grafik Akurasi Model 1D-CNN



Gambar 3 . Grafik Loss Model 1D-CNN


E. Hasil Evaluasi Model

Evaluasi dilakukan menggunakan **30** klip video yang tidak digunakan pada proses pelatihan. Pengujian ini bertujuan untuk mengetahui kemampuan model dalam mengenali data baru pada kategori “sempurna” dan “tidak sempurna”. Hasil prediksi model dibandingkan dengan label sebenarnya untuk memperoleh nilai *precision*, *recall*, *F1-score*, dan *accuracy*. Hasil evaluasi masing-masing kelas disajikan pada Tabel 6.

Tabel 6. Hasil Evaluasi Model

Kelas	Precision	Recall	F1-Score	Support
Tidak Sempurna	0,62	0,53	0,57	15
Sempurna	0,59	0,67	0,62	15
Accuracy		0,60	30	
Macro Avg	0,60	0,60	0,60	30
Weighted Avg	0,60	0,60	0,60	30

Berdasarkan Tabel 6, model memperoleh nilai *accuracy* sebesar **0,60** atau **60%** pada data uji. Pada kelas “tidak sempurna”, model memperoleh nilai *precision* sebesar **0,62**, *recall* sebesar **0,53**, dan *F1-score* sebesar **0,57**. Sementara itu, pada kelas “sempurna”, model memperoleh nilai *precision* sebesar **0,59**, *recall* sebesar **0,67**, dan *F1-score* sebesar **0,62**. Hasil tersebut menunjukkan bahwa model sudah mampu mengenali kedua kelas, meskipun masih terdapat kesalahan klasifikasi pada beberapa data uji.



Gambar 4. Confusion Matrix Model 1D-CNN

Berdasarkan Gambar 4, model berhasil mengklasifikasikan 8 data pada kelas “tidak sempurna” dan 10 data pada kelas “sempurna” secara benar. Namun, terdapat 7 data “tidak sempurna” yang diprediksi sebagai “sempurna” serta 5 data “sempurna” yang diprediksi sebagai “tidak sempurna”. Jumlah prediksi benar sebanyak 18 dari 30 data uji menghasilkan nilai *accuracy* sebesar 60%. Hasil tersebut menunjukkan bahwa model masih mengalami kesulitan dalam membedakan beberapa pola gerakan yang memiliki kemiripan posisi tubuh antara kelas “sempurna” dan “tidak sempurna”.

IV. KESIMPULAN

Berdasarkan hasil penelitian, proses klasifikasi gerakan tolak peluru menggunakan MediaPipe Pose dan 1D-CNN telah berhasil dilakukan melalui tahapan pengumpulan data, *preprocessing*, ekstraksi *landmark* tubuh, pelatihan model, dan evaluasi model. Data yang digunakan berjumlah **150 klip video** yang terdiri dari tiga fase gerakan, yaitu awalan, dorongan, dan sikap akhir, dengan dua kategori kelas “sempurna” dan “tidak sempurna”. Hasil ekstraksi MediaPipe Pose menghasilkan *dataset* fitur berukuran **150 × 30 × 99**, yang kemudian digunakan sebagai masukan pada model 1D-CNN. Hasil pelatihan menunjukkan bahwa model memperoleh *training accuracy* sebesar **88,54%** dan *validation accuracy* sebesar **70,83%**. Sementara itu, hasil evaluasi pada data uji memperoleh *accuracy* sebesar **60%**, dengan *F1-score* sebesar **0,57** pada kelas “tidak sempurna” dan **0,62** pada kelas “sempurna”. Hasil tersebut menunjukkan bahwa

model sudah mampu mengenali kedua kelas, meskipun masih terdapat kesalahan klasifikasi. Oleh karena itu, pendekatan MediaPipe Pose dan *1D-CNN* memiliki potensi untuk digunakan dalam klasifikasi gerakan tolak peluru, tetapi performanya masih dapat ditingkatkan melalui penambahan variasi data, perbaikan kualitas pelabelan, dan penyesuaian arsitektur model.

DAFTAR PUSTAKA

- [1] A. Akkase, U. N. Makassar, J. A. P. Pettarani, K. Rappocini, K. Makassar, and S. Selatan, "Analisis Gerak Biomekanika Pada Tolak Peluru Gaya O'Brien," *Journal Physical Health Recreation (JPHR)*, vol. 4, no. 1, pp. 171–178, Nov. 2023, doi: <https://doi.org/10.55081/jphr.v4i1.1668>.
- [2] M. T. Mubayyin, E. M. A. Anantacia, C. Salsabila, and M. F. Hidayattullah, "Klasifikasi dan deteksi pose pilates menggunakan mediapipe dan random forest classifier," *Teknosains: Media Informasi Sains dan Teknologi*, vol. 19, no. 1, pp. 56–63, Jun. 2025, doi: [10.24252/teknosains.v19i1.53698](https://doi.org/10.24252/teknosains.v19i1.53698).
- [3] F. Daniel Tanugraha, H. Pratikno, M. Musayanah, and W. Indah Kusumawati, "Pengenalan Gerakan Olahraga Berbasis (Long Short- Term Memory) Menggunakan Mediapipe," *Journal of Advances in Information and Industrial Technology*, vol. 4, no. 1, pp. 37–45, May 2022, doi: [10.52435/jaiit.v4i1.182](https://doi.org/10.52435/jaiit.v4i1.182).
- [4] V. Jericho and T. H. Rochadiani, "Implementasi CNN dan MediaPipe dalam Peningkatan Efektivitas Stretching pada Olahraga Futsal," *Technomedia Journal*, vol. 9, no. 3, pp. 387–398, Feb. 2025, doi: [10.33050/tmj.v9i3.2294](https://doi.org/10.33050/tmj.v9i3.2294).
- [5] F. H. Adiba, P. Kasih, and M. A. D. W. Dara, "Implementation and Evaluation of the K – Nearest Neighbors Algorithm in Badminton Movement Classification," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 14, no. 4, pp. 489–498, Oct. 2025, doi: [10.32736/sisfokom.v14i4.2441](https://doi.org/10.32736/sisfokom.v14i4.2441).
- [6] R. Andriawan, P. Kasih, and D. P. Pamungkas, "Implementasi Teknik Ekstraksi Pose dengan MediaPipe dan Klasifikasi Random Forest untuk Penentuan Kualitas Gerakan Push-Up," *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 9, pp. 1723–1732, 2025, doi: <https://doi.org/10.29407/zf3hpm03>.
- [7] L. A. Sindhikara, A. Sanjaya, and A. Bagus, "Deteksi Gerakan Servis Bulutangkis Menggunakan Metode K-Nearest Neighbors (KNN) Berbasis Komputer Vision," *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 9, pp. 2111–2118, 2025, doi: <https://doi.org/10.29407/ygyvja37>.
- [8] Muhammad Rizaldi, Rudi Heriansyah, and Nazori Suhandi, "Pengenalan Gerakan Tangan untuk Kontrol Slide Presentasi Menggunakan Framework Mediapipe, OpenCV, dan Model LSTM," *Jurnal Publikasi Teknik Informatika*, vol. 4, no. 3, pp. 98–111, Sep. 2025, doi: [10.55606/jupti.v4i3.5332](https://doi.org/10.55606/jupti.v4i3.5332).
- [9] Y. Effendi, Y. Kristian, L. Zaman, H. Yutanto, and A. History, "Jurnal Teknologi dan Manajemen Informatika Pemanfaatan Mediapipe Body Pose Estimation dan Dynamic Time Warping untuk Pembelajaran Tari Remo Article Info ABSTRACT," *Jurnal Teknologi dan Manajemen Informatika*, vol. 9, no. 2, pp. 183–190, 2023, doi: <https://doi.org/10.26905/jtmi.v9i2.10408>.
- [10] B. C. Santoso, H. Santoso, and J. Sandjaya, "DEVELOPMENT OF INDEPENDENT TAEKWONDO TRAINING MACHINE LEARNING WITH 3D POSE MODEL

- MEDIAPIPE,” *Sinkron : Jurnal dan Penelitian Teknik Informatika*, vol. 8, no. 3, pp. 1427–1434, Jul. 2023, doi: 10.33395/sinkron.v8i3.12571.
- [11] M. A. B. Prasetya, Harits Ar Rosyid, and M. Zainal Arifin, “Accuracy Evaluation of 2D MediaPipe-Based Pose Estimation for Archery Posture Detection Using N-MPJPE,” *JURNAL TEKNIK INFORMATIKA*, vol. 19, no. 1, pp. 109–121, Apr. 2026, doi: 10.15408/jti.v19i1.49778.
- [12] B. Sobari, M. Moedjiono, and M. A. Rizkiawan, “Pose Analysis and Classification in Shooting Sport Using Convolutional Neural Network and Long Short-Term Memory,” *Jurnal Informatika*, vol. 12, no. 2, pp. 122–130, Oct. 2025, doi: 10.31294/inf.v12i2.25566.
- [13] A. Bera, M. Nasipuri, O. Krejcar, and D. Bhattacharjee, “Fine-Grained Sports, Yoga, and Dance Postures Recognition: A Benchmark Analysis,” Aug. 2023, doi: 10.1109/TIM.2023.3293564.
- [14] G. T. Tendra, D. J. Jollyta, and Sumijan, “Development of an Attention-Based Convolutional Neural Network-Long Short-Term Memory Model for Real-Time Ergonomic Analysis of Sitting Posture,” *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 25, no. 2, pp. 287–298, Mar. 2026, doi: 10.30812/matrik.v25i2.5678.
- [15] C. Z. Noorta, M. F. Rais, M. I. Alfatrah, U. D. Fatmawati, and H. A. Danang Rimbawa, “Machine learning-based approach for evaluating physical fitness through motion detection,” vol. 14, no. 1, pp. 2809–1884, 2025, [Online]. Available: www.ejournal.isha.or.id/index.php/Mandiri
- [16] K. Swee Sim, S. Wei Wong, A. Low, A. Prademon Yunus, and C. Peng Lim, “Real-Time Digital Assistance for Exercise: Exercise Tracking System with MediaPipe Angle Directive Rules,” *International Journal on Informatics Visualization*, vol. 8, no. 4, pp. 2380–2387, Dec. 2024, doi: 10.62527/joiv.8.4.2993.
- [17] V. Suhandi and H. Santoso, “Personal Training with Tai Chi: Classifying Movement using Mediapipe Pose Estimation and LSTM,” *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 2, pp. 767–775, Sep. 2024, doi: 10.47065/bits.v6i2.5536.
- [18] R. Krisna Pambudi and N. Wijaya, “Sistem Finding Choreography HipHop Basic Menggunakan MediaPipe Body Pose Estimation untuk Dancer,” *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 15, no. 1, pp. 1–11, 2026, doi: 10.35889/jutisi.v15i1.3404.
- [19] L. Fitriani and I. Nurhakim, “Sistem Deteksi Gerakan Tangan Untuk Pengendalian Cursor Pada Presentasi Berbasis Opencv dan Mediapipe,” *Jurnal Algoritma*, vol. 22, no. 2, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2485.
- [20] M. Abdul muthalib, I. Irfan, K. Kartika, and S. M. Selamat Meliala, “PENGIRAAN POSE MODEL MANUSIA PADA REPETISI KEBUGARAN AI PEMOGRAMAN PYTHON BERBASIS KOMPUTERISASI,” *INFOTECH journal*, vol. 9, no. 1, pp. 11–19, Jan. 2023, doi: 10.31949/infotech.v9i1.4233.