



Tersedia Online : <http://e-journals.unmul.ac.id/>

ADOPSI TEKNOLOGI DAN SISTEM INFORMASI (ATASI)

Alamat Jurnal : <http://e-journals2.unmul.ac.id/index.php/atasi/index>



Estimasi Gerakan Olahraga *Push Up* Menggunakan *Multilayer Perceptron Classifier* dan *Mediapipe Pose*

Bimasakti Cahyo Utomo ¹⁾, Awang Harsa Kridalaksana ²⁾, Muhammad Ibadurrahman Arrasyid Supriyanto ^{3)*}, Chalsi Mala Sari ⁴⁾, Hidayatul Muttaqien ⁵⁾, Muhammad Labib Jundillah ⁶⁾, Vina Zahrotun Kamila ⁷⁾

^{1,2)} Informatika, Fakultas Teknik, Universitas Mulawarman

^{3,5,6,7)} Sistem Informasi, Fakultas Teknik, Universitas Mulawarman

⁴⁾ Teknik Sipil, Fakultas Teknik, Universitas Mulawarman

E-Mail : bimasakticahyoutomo@gmail.com¹⁾; awanghk@unmul.ac.id²⁾; ibadurrahman@ft.unmul.ac.id³⁾; chalsimalasari@ft.unmul.ac.id, hidayatul.muttaqien@unmul.ac.id, muhammadjundillah@ft.unmul.ac.id, vinakamila@ft.unmul.ac.id

ARTICLE INFO

Article history:

Received : 07/08/2026

Revised : 27/08/2026

Accepted : 28/08/2026

Available online : 31/08/2026

Keywords:

Push Up

Multilayer Perceptron

Mediapipe

Exercise

Kata Kunci :

Push Up

Multilayer Perceptron

Mediapipe

Olahraga

ABSTRACT

Push ups are a widely utilized exercise for developing arm and chest muscle strength. This study aims to develop and evaluate a model based on Multilayer Perceptron (MLP) and MediaPipe Pose to estimate push up movement techniques. The model utilizes human body keypoints extracted from an image dataset, which are classified into three distinct classes: the ascend phase, descend phase, and non-pushup. Model evaluation using a confusion matrix and macro averaging demonstrated an accuracy of 89.8%, with a recall, precision, and F1-score of 88.8%, 89.7%, and 89.2%, respectively. Furthermore, movement form consistency was evaluated using videos captured from three different viewpoints based on the number of points and average confidence. The results indicate that the model achieves optimal performance from the side and diagonal viewpoints compared to the front viewpoint. This research contributes a keypoint-based model to enable a more objective assessment of push up forms.

ABSTRAK

Olahraga *push up* sangat diminati masyarakat untuk melatih kekuatan otot lengan dan dada. Penelitian ini bertujuan mengembangkan dan mengevaluasi model berbasis Multilayer Perceptron (MLP) dan MediaPipe Pose untuk mengestimasi teknik gerakan *push up*. Model memanfaatkan keypoints tubuh manusia yang diekstrak dari *dataset* gambar, yang diklasifikasikan ke dalam tiga kelas: fase *ascend*, *descend*, dan *non-pushup*. Pengujian model menggunakan confusion matrix dan macro average menunjukkan akurasi sebesar 89.8%, serta nilai recall, precision, dan F1-score masing-masing sebesar 88.8%, 89.7%, dan 89.2%. Selain itu, evaluasi kesesuaian gerakan (form) diuji menggunakan video dari tiga sudut pandang berbeda berdasarkan jumlah poin dan average confidence. Hasilnya menunjukkan performa model paling optimal pada sudut pandang samping dan diagonal dibandingkan sudut depan. Penelitian ini berkontribusi dalam menyediakan model berbasis keypoints untuk mendeteksi form *push up* secara lebih objektif.

1. PENDAHULUAN

Olahraga telah menjadi kegiatan dasar yang banyak dilakukan oleh masyarakat untuk menjaga kebugaran tubuh. Menurut Kementerian Pemuda dan Olahraga, indeks partisipasi masyarakat dalam berolahraga pada tahun 2024 sebesar 0,263, meningkat 0,009 poin dibandingkan dengan data tahun 2023 yang sebesar 0,254 (Kementerian Pemuda dan Olahraga, 2024). Salah satu olahraga yang paling banyak diminati dan paling mudah diakses oleh masyarakat adalah olahraga *push up* yang berfokus melatih kekuatan otot lengan dan dada. *Push up* termasuk dalam olahraga strenght training. Anak-anak berumur 5-17 tahun perlu melakukan strenght training

*) Corresponding Author

<https://doi.org/10.30872/atasi.v5i2.5102>

2026 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

setidaknya 3 kali seminggu dan orang dewasa berumur 18-64 tahun dan lansia berumur 65 keatas perlu melakukan strenght training setidaknya 2 kali seminggu (World Health Organization, 2024).

Form gerakan atau teknik gerakan dalam melakukan gerakan olahraga merupakan aspek yang sangat penting dalam meningkatkan efektifitas peningkatan volume otot. Menjaga form atau teknik gerakan yang benar saat berolahraga penting untuk mencegah cedera dan memaksimalkan peningkatan massa otot. Mendeteksi kesalahan dalam teknik latihan secara alami memerlukan estimasi pose tubuh manusia (Parmar et al., 2022). Salah satu penyebab utama cedera dalam olahraga terutama *strenght training* adalah teknik atau *form* yang kurang tepat, cedera ini umumnya terjadi pada sendi bahu, lutut, siku, serta ruas tulang belakang (Bonilla et al., 2022).

Computer Vision muncul sebagai bidang teknologi yang dapat membantu mendeteksi jenis pergerakan manusia melalui analisis visual dari gambar, video, atau secara langsung dari kamera. Teknologi ini telah diterapkan pada studi terkait seperti mendeteksi pose *pilates*, mendeteksi gerakan *fitness* dan menganalisis gerakan *gym* (Mubayyin et al., 2025), (Arwintoro et al., 2025), (Attar et al., 2025). *Deep Learning* telah menjadi pendekatan yang sangat sukses dalam *computer vision* (Chai et al., 2021). *Multilayer Perceptron* (MLP) merupakan salah satu metode berbasis *deep learning* yang telah diterapkan pada studi terkait untuk mendeteksi gerakan tubuh manusia seperti mendeteksi *form bicep curl* dan klasifikasi *American Sign Language* (Bernardo et al., 2023), (Remiro et al., 2023). Penelitian ini mengimplementasikan *MLPClassifier* dengan memanfaatkan *MediaPipe Pose* sebagai *feature extractor* untuk mendeteksi keypoints tubuh manusia. *MediaPipe Pose* digunakan untuk menghasilkan koordinat *landmark*, yang kemudian dijadikan input bagi MLP untuk proses klasifikasi. Pendekatan ini memungkinkan sistem melakukan identifikasi pose tubuh.

2. TINJAUAN PUSTAKA

A. Penelitian Terdahulu

Tabel 1 merangkum perkembangan terkini di bidang deteksi dan evaluasi gerakan olahraga (2022–2025) yang relevan dengan penelitian ini, mencakup metode yang digunakan, jenis aktivitas fisik yang dianalisis, temuan utama, serta keterbatasan yang teridentifikasi dari penelitian-penelitian sebelumnya. Metode-metode tersebut meliputi penggunaan estimasi pose (pose estimation) yang dikombinasikan dengan berbagai model seperti YOLO, LSTM, Random Forest, dan perhitungan sudut berbasis aturan (rule-based angle calculation). Tabel ini juga menyoroti kesenjangan (gap) yang masih ada, khususnya terbatasnya penerapan model Multilayer Perceptron (MLP) serta minimnya penelitian yang berfokus pada klasifikasi fase gerakan *push up* yang diintegrasikan dengan evaluasi bentuk (form) gerakan. Kesenjangan-kesenjangan inilah yang menjadi dasar bagi pengembangan pendekatan yang diusulkan dalam penelitian ini.

Tabel 1. Ringkasan Penelitian Terdahulu

Penulis	Metode	Temuan
Arwintoro et al., 2025	Pose Estimation, YOLOv11	Mencapai akurasi, presisi, recall, dan F1-score yang konsisten sebesar 73,3% dalam mengklasifikasikan teknik squat yang benar vs. salah; performa lebih tinggi pada peserta yang sudah terampil (78,6%) dibandingkan pemula (68,8%), dan kesalahan terkait kedalaman ($<60^\circ$) terdeteksi dengan rata-rata deteksi 100%.
Attar et al., 2025	Pose Estimation, LSTM	Model klasifikasi Shoulder Press mencapai akurasi validasi 100%, sedangkan model Bicep Curl mencapai akurasi validasi 96,3%, menunjukkan bahwa model LSTM berbasis pose dapat secara andal membedakan bentuk latihan beban bebas yang benar dari yang salah.
Parmar et al., 2022	MediaPipe, Random Forest Classifier	Model Random Forest yang dilatih menggunakan titik kunci (keypoints) pose pilates hasil ekstraksi MediaPipe mencapai akurasi 87%, presisi 90%, recall 85%, dan F1-score 87,5% dalam membedakan pose pilates yang benar dari yang salah.
Suraju et al., 2025	Pose Estimation, MediaPipe	Ambang batas sudut siku dan pinggul (siku $>160^\circ$ untuk posisi "atas" dan $<95^\circ$ untuk posisi "bawah") yang diekstraksi melalui MediaPipe memungkinkan penghitungan repetisi <i>push up secara real-time</i> serta estimasi kalori, meskipun akurasi menurun pada kondisi pencahayaan buruk atau sendi yang terhalang (occluded).
Kwon & Kim, 2022	MediaPipe Pose	Menetapkan kriteria berbasis sudut untuk koreksi squat (sudut pinggul 60° – 120°) dan <i>push up</i> (sudut siku 70° – 100° , sudut tubuh mendekati 180°), serta menampilkan umpan balik koreksi secara real-time dan jumlah repetisi ketika kriteria terpenuhi.

Berdasarkan referensi-referensi terkait yang telah dipaparkan, kebaruan (novelty) dari penelitian ini dibandingkan dengan penelitian-penelitian sebelumnya terletak pada objek analisis dan metode yang digunakan. Penelitian ini secara khusus berfokus pada gerakan *push up sebagai* objek kajian, serta menerapkan Multilayer Perceptron (MLP) sebagai model klasifikasi untuk menganalisis gerakan tersebut.

B. Strenght Training

Strenght Training merupakan suatu bentuk aktivitas fisik yang umumnya terstruktur dan terencana, yang melibatkan usaha intensif melawan suatu bentuk resistansi dengan tujuan untuk meningkatkan kekuatan otot

(Barbieri & Zaccagni, 2013). *Strength training* bertujuan untuk meningkatkan kekuatan maksimal seseorang yaitu kemampuan otot menghasilkan gaya terbesar tanpa mempertimbangkan waktu serta kekuatan relatif, yaitu kemampuan menghasilkan gaya tinggi dibandingkan dengan massa tubuh (Jess Fassnidge, 2025).

C. Push Up


Push up adalah latihan *closed chain* yang umum digunakan untuk meningkatkan stabilitas dinamis pada ekstremitas atas melalui peningkatan *proprioepsi*, kontrol neuromuskular, dan kekuatan gelang bahu (Kowalski et al., 2022).

D. Form Push Up

Push up standar memerlukan kekakuan atau stabilisasi pada sendi lutut, sendi panggul, pelvis, dan tulang belakang untuk menjaga tubuh tetap dalam posisi lurus dari kepala hingga kaki, sementara sendi bahu dan siku melakukan gerakan fleksi dan ekstensi untuk mengangkat dan menurunkan tubuh, serta tulang belikat (skapula) melakukan gerakan retraksi dan protraksi untuk memfasilitasi rentang gerak sendi bahu (glenohumeral) (Contreras et al., 2012). Posisi ideal untuk tubuh pada gerakan *push up* adalah dari 200° ascend hingga 160° pada descend (Kwon & Kim, 2022). Aktivasi otot terjadi pada saat siku membentuk sudut diantara 55° - 75° (San Juan et al., 2015).

E. Multilayer Perceptron

Salah satu arsitektur ANN (*Artificial Neural Network*) yang paling dikenal adalah *Multilayer Perceptron* (MLP), yang secara struktural merupakan generalisasi dari neuron buatan yang disebut *Rosenblatt perceptron* yaitu neuron buatan yang menggunakan fungsi aktivasi *Heaviside*. MLP memiliki kemampuan aproksimasi universal: sebuah MLP dapat mengaproksimasi fungsi apa pun yang kontinu, terbatas, terdiferensiasi, dan nonlinier dengan *input* terdefinisi dalam ruang kompak dengan tingkat presisi *arbitrer*. MLP mengatur neuron dalam beberapa lapisan yang saling terhubung berurutan, di mana setiap lapisan terdiri dari susunan neuron-neuron paralel. MLP mencakup *input layer*, satu atau lebih *hidden layer*, dan *output layer* (Costa et al., 2023). Contoh ilustrasi model MLP dapat dilihat pada Gambar 2.5.



Gambar 1. Ilustrasi Model MLP

Layer pertama ($l = 0$) adalah *input layer*, di mana neuron-neuronnya menerima variabel *input* dari permasalahan. Setiap neuron pada lapisan ini merupakan neuron khusus yang hanya meneruskan nilai dari suatu fitur input ke *node-node* pada *hidden layer* yaitu $y(l=0)_j = x_j$. Neuron pada lapisan tersembunyi ($0 < l < L$) dan *output layer* ($l = L$) adalah neuron buatan standar yang menerima *input* berupa *output* neuron-neuron dari *layer* sebelumnya. Layer terakhir adalah *output layer*, yang neuron-neuronnya menghasilkan nilai variabel *output* dari permasalahan. Satu atau lebih *hidden layer* dapat digunakan. *Hidden layer* bertanggung jawab untuk memetakan sinyal input secara nonlinier ke ruang lain sesuai kebutuhan permasalahan. Karena kombinasi fungsi linear tetap menghasilkan fungsi linear, fungsi aktivasi pada *node-node* tersembunyi biasanya merupakan fungsi nonlinier (Costa et al., 2023).

F. Mediapipe

MediaPipe adalah sebuah framework yang dirancang untuk mengimplementasikan machine learning tingkat produksi yang membutuhkan penyusunan pipeline untuk melakukan inferensi terhadap data sensor apa pun. Framework ini menyediakan kode yang menyertai penelitian, serta memungkinkan pengembangan prototipe teknologi. MediaPipe dikembangkan oleh Google untuk menyelesaikan berbagai permasalahan berbasis machine learning, seperti *Face Detection*, *Face Mesh*, *Iris*, *Hands*, *Pose*, *Holistic*, *Hair Segmentation*, *Object Detection*, *Box Tracking*, *Instant Motion Tracking*, *Objectron*, dan *KNIFT* (Indriani et al., 2021).

G. Confusion Matrix

Confusion matrix didefinisikan sebagai matriks yang menunjukkan perbandingan antara kelas hasil prediksi dengan kelas aktual. Matriks ini memungkinkan perhitungan berbagai metrik kinerja, seperti *accuracy*, *precision*, *recall*, dan *Matthews Correlation Coefficient (MCC)*, serta teknik evaluasi seperti *Receiver Operating Characteristic (ROC)* dan *Area Under the Curve (AUC)* (Markoulidakis et al., 2021).

Tabel 2. Struktur Confusion Matrix

Kelas	Kelas Aktual		
	A	B	C
A	n(A, A)	n(A, B)	n(A, C)
B	n(B, A)	n(B, B)	n(B, C)
C	n(C, A)	n(C, B)	n(C, C)

Keterangan : data(kelas prediksi, kelas aktual)

H. Macro Average

Macro average adalah pendekatan menghitung rata-rata aritmatika sederhana dari statistik setiap kelas (Farhadpour et al., 2024). Statistik tersebut meliputi *recall*, *precision* dan *F1-Score*. *Macro average* menetapkan bobot yang sama untuk setiap kelas tanpa mempertimbangkan jumlah datanya (Rainio et al., 2024). Rumus *macro average* ditunjukkan pada Formula (1).

$$\text{Macro Average} = \frac{1}{N} \sum_{i=1}^N \text{metric} \dots \dots \dots (1)$$

Keterangan :

- N = Jumlah kelas
- Metric = recall, precision, F1-Score

3. METODE PENELITIAN

A. Pengumpulan dan Perancangan Data

Proses pengumpulan data dilakukan dengan memanfaatkan *dataset* yang tersedia pada platform publik seperti Kaggle. Data yang dikumpulkan berupa gambar gerakan *push up* serta beberapa gerakan umum yang berpotensi muncul selama proses deteksi, seperti berdiri, berjalan, berlari, dan melompat. Seluruh data gambar disimpan dalam format .jpg dan digunakan sebagai data pelatihan model. Data tersebut kemudian dikelompokkan ke dalam tiga kelas, yaitu *ascend*, *descend*, dan *non-push up*. Kelas *ascend* merepresentasikan fase gerakan naik pada *push up*, kelas *descend* merepresentasikan fase gerakan turun, sedangkan kelas *non pushup* mencakup gerakan selain *push up*. Selain data gambar, penelitian ini juga menggunakan data video gerakan *push up* yang direkam dari tiga sudut pandang berbeda, yaitu depan, samping, dan diagonal, sebagai data pengujian sistem.

Perancangan data dilakukan dengan menggabungkan *dataset* gerakan *push up* dan *non pushup* yang diperoleh dari berbagai sumber. *Dataset* yang digunakan dipilih berdasarkan kesesuaiannya dengan kebutuhan penelitian, khususnya untuk menyediakan variasi gerakan *push up* dan gerakan lain yang berpotensi terdeteksi ketika sistem digunakan. *Dataset* yang digunakan dalam penelitian ini meliputi HMDB51 (*Human Movement Database 51*) sebagai sumber data berbagai aktivitas atau gerakan manusia dan *Push Up Exercise* sebagai *dataset* pendukung yang berisi hanya gerakan *push up*. Data dari kedua *dataset* tersebut selanjutnya diseleksi, dikelompokkan, dan disesuaikan dengan tiga kelas yang digunakan dalam proses pelatihan model, yaitu *ascend*, *descend*, dan *non pushup*. Data dari kedua *dataset* yang digabungkan menghasilkan *dataset* yang berisi 828 data gambar, dengan 305 gambar untuk *ascend*, 290 gambar untuk *descend* dan 233 gambar untuk *non pushup*.

B. Pengolahan Data

Pengolahan data merupakan tahap awal yang perlu dilakukan sebelum dilaksanakannya pelatihan model. Pada tahap pengolahan data, data yang sudah dikumpulkan akan diproses melalui serangkaian langkah seperti ekstraksi fitur untuk mengubah data gambar menjadi vektor numerik berbasis koordinat keypoint tubuh agar dapat diproses menggunakan MLP, pembagian data (*data splitting*) yang membagi data dalam *dataset* menjadi train set dan test set.

1. Normalisasi Koordinat Keypoint

Koordinat keypoint dinormalisasi relatif dari titik pusat pinggang, hal ini dilakukan agar koordinat keypoint yang didapatkan tidak berubah berdasarkan letak badan yang terdeteksi pada data gambar. Rumus menentukan pusat pinggang dan rumus normalisasi setiap landmark dapat dilihat pada Formula (2) dan Formula (3).

$$\begin{aligned} Cx &= (xLH + xRH)/2 \\ Cy &= (yLH + yRH)/2 \dots \dots \dots (2) \\ Cz &= (zLH + zRH)/2 \end{aligned}$$

Keterangan :

- xLH, yLH, zLH = koordinat Left Hip
- xRH, yRH, zRH = koordinat Right Hip
- Cx, Cy, Cz = koordinat pusat pinggul (titik referensi)

$$\begin{aligned}x_i' &= x_i - C_x \\y_i' &= y_i - C_y \dots\dots\dots(3) \\z_i' &= z_i - C_z\end{aligned}$$

Keterangan :

- x_i, y_i, z_i = koordinat asli landmark ke- i hasil deteksi MediaPipe Pose
- x_i', y_i', z_i' = koordinat landmark ke- i setelah dinormalisasi

2. Ekstraksi Fitur

Ekstraksi fitur penelitian ini dilakukan menggunakan MediaPipe untuk mendeteksi *keypoint* tubuh manusia yang terdapat pada data gambar. Koordinat *keypoints* yang dihasilkan kemudian digunakan sebagai vektor fitur *input* bagi model MLP. Hasil ekstraksi fitur dapat dilihat pada Tabel 3.

Tabel 3. Hasil Ekstraksi Fitur Menggunakan MediaPipe

Index	NOSE_x	NOSE_y	NOSE_z	...	NOSE_visibility
0	-0.336706	0.115288	-0.531326	...	0.990748
1	-0.406294	0.173210	-0.525199	...	0.993279
2	-0.372506	0.109692	-0.492736	...	0.984745
...	...	...	...	...	...
762	0.005724	-0.327086	0.197276	...	0.999810

3. Pembagian Data

Pembagian data bertujuan untuk membagi *dataset* menjadi bagian yang digunakan sebagai data *train* dan data *test*. Sebelum dilakukannya pembagian data, perlu dilakukan proses *label encoding* yang berfungsi untuk mengonversi label kelas yang berbentuk kategorikal menjadi nilai numerik. Proses ini diperlukan karena algoritma MLP hanya dapat menerima input dalam bentuk numerik. Rasio pembagian data yang digunakan adalah rasio 80:20, di mana 80% data digunakan untuk proses pelatihan model (*train set*) dan 20% data digunakan untuk proses pengujian (*test set*).


C. Perancangan Proses

Perancangan proses dilakukan untuk menggambarkan alur kerja sistem mulai dari tahap pengumpulan data hingga model dapat digunakan pada sistem. *Google Colab* digunakan untuk melakukan pelatihan model karena *Google Colab* menyediakan GPU yang dibuat khusus untuk pelatihan model. Proses pelatihan model diawali dengan mengimpor modul *MLPClassifier* dari library *scikit-learn*, kemudian dilanjutkan dengan mendefinisikan arsitektur serta *hyperparameter* model yang akan digunakan. *Hyperparameter* yang ditentukan meliputi jumlah dan ukuran *hidden layer*, fungsi aktivasi, metode optimasi, *learning rate*, serta teknik regularisasi untuk mengurangi risiko *overfitting*. Setelah konfigurasi model selesai, data hasil ekstraksi fitur akan dibagi menjadi data pelatihan dan data validasi. Selanjutnya, model dilatih menggunakan data pelatihan hingga memenuhi kriteria *early stopping* yang telah ditetapkan. *Hyperparameter* pelatihan dapat dilihat pada Tabel 4.

Tabel 4. *Hyperparameter* Pelatihan

No	<i>Hyperparameter</i>	Keterangan
1	<code>hidden_layer_sizes = (128, 64, 32)</code>	Menentukan arsitektur jaringan saraf yang terdiri dari tiga <i>hidden layer</i> dengan masing-masing 128, 64, dan 32 <i>neuron</i> . Arsitektur ini dipilih untuk menangkap pola non-linear yang kompleks dari fitur pose hasil ekstraksi MediaPipe.
2	<code>activation = 'relu'</code>	Fungsi aktivasi <i>Rectified Linear Unit (ReLU)</i> digunakan karena mampu mempercepat proses konvergensi dan mengurangi masalah <i>vanishing gradient</i> pada jaringan saraf dalam.
3	<code>solver = 'adam'</code>	Optimizer <i>Adaptive Moment Estimation (Adam)</i> digunakan karena efektif untuk dataset berukuran sedang dan mampu menyesuaikan <i>learning rate</i> secara adaptif selama proses pelatihan.
4	<code>alpha = 0.0001</code>	Parameter regularisasi L2 yang berfungsi untuk mencegah <i>overfitting</i> dengan memberikan penalti terhadap bobot yang terlalu besar.
5	<code>batch_size = 'auto'</code>	Ukuran <i>mini-batch</i> ditentukan secara otomatis oleh sistem, disesuaikan dengan jumlah data pelatihan.
6	<code>max_iter = 500</code>	Menentukan jumlah maksimum iterasi pelatihan.
7	<code>shuffle = True</code>	Data pelatihan diacak pada setiap iterasi untuk mengurangi bias urutan data.
8	<code>random_state = 42</code>	Digunakan untuk memastikan hasil pelatihan dapat direproduksi.
9	<code>early_stopping = True</code>	Proses pelatihan akan dihentikan lebih awal jika performa model pada data validasi tidak mengalami peningkatan, sehingga dapat mencegah <i>overfitting</i> .
10	<code>validation_fraction = 0.1</code>	Sebanyak 10% dari data pelatihan digunakan sebagai data validasi selama proses pelatihan.
11	<code>n_iter_no_change = 20</code>	Menentukan jumlah iterasi tanpa peningkatan performa sebelum pelatihan dihentikan.
12	<code>verbose = True</code>	Menampilkan informasi proses pelatihan secara detail untuk memantau konvergensi model.

Pertama, *dataset* akan diperoleh dari *website Kaggle*, kemudian dilakukan proses *preprocessing* yaitu pembagian data (*split dataset*). Selanjutnya, proses pelatihan model (*training*) dilakukan menggunakan *Google Colab*. Setelah model selesai dilatihkan dilakukan evaluasi untuk meninjau performa model menggunakan *confusion matrix*. Implementasi model pada platform *Streamlit* diawali dengan proses *loading* model yang telah disimpan sebelumnya. Setelah pengguna mengunggah video, sistem melakukan pendeteksian gerakan tubuh pada setiap *frame* video. Setiap *frame* yang tertangkap kamera kemudian diproses menggunakan *MediaPipe Pose* untuk mendeteksi *landmark* tubuh. Apabila pose berhasil terdeteksi, *frame* akan melalui tahap pemrosesan lanjutan berupa ekstraksi dan normalisasi koordinat *keypoint* seperti yang dilakukan pada proses pengolahan data sebelumnya, yang selanjutnya digunakan sebagai input ke model *Multi Layer Perceptron (MLP)* untuk melakukan klasifikasi gerakan. Hasil klasifikasi berupa kelas gerakan yang terdeteksi kemudian ditampilkan secara langsung pada *frame* yang telah diproses. Alur keseluruhan proses implementasi sistem ini ditunjukkan pada Gambar 2.



Gambar 2. Alur Deteksi Pada *Streamlit*

D. Perancangan Pengujian

Perancangan pengujian dilakukan untuk mengevaluasi kinerja model setelah proses pelatihan dengan menggunakan metrik evaluasi yang sesuai untuk permasalahan klasifikasi. Evaluasi model dilakukan menggunakan *confusion matrix*, *recall*, *F1-score*, dan *macro average* untuk mengukur kemampuan model dalam mengidentifikasi setiap kelas secara menyeluruh. Selanjutnya, model yang telah dilatih diimplementasikan pada sistem deteksi *form push up* untuk mengidentifikasi fase gerakan yang dilakukan oleh pengguna. Model dievaluasi tanpa membandingkan dengan model klasifikasi lain.


Tabel 5. Kriteria Poin Sudut *Form*

No	Sendi (Keypoints)	Fase	Rentang Sudut	Point	Keterangan
1	Siku (<i>Shoulder-Elbow-Wrist</i>)	<i>Descend</i>	80°–100°	10	Gerakan sangat tepat
			60°–79° atau 101°–120°	7	Gerakan cukup tepat
			< 60° atau > 120°	4	Gerakan tidak tepat
		<i>Ascend</i>	160°–180°	10	Gerakan sangat tepat
			140°–159°	7	Gerakan cukup tepat
			< 140°	4	Gerakan tidak tepat
2	Pinggang (<i>Shoulder-Hip-Knee</i>)	Semua	170°–180°	5	Tubuh lurus
			150°–169°	3	Sedikit melengkung
			< 150°	0	Pinggang turun atau naik berlebihan

Proses deteksi *form push up* memanfaatkan informasi koordinat *keypoints* tubuh yang diperoleh melalui *MediaPipe Pose*. Berdasarkan koordinat tersebut, sistem melakukan perhitungan sudut (*angle*) pada beberapa sendi yang relevan terhadap kualitas gerakan *push up*. Sudut siku dihitung menggunakan *keypoints* bahu, siku, dan pergelangan tangan untuk mengidentifikasi perubahan posisi lengan pada setiap fase gerakan, sedangkan sudut pinggang dihitung berdasarkan *keypoints* bahu, pinggang, dan lutut untuk menilai kelurusan posisi tubuh selama pelaksanaan gerakan. Nilai sudut yang diperoleh kemudian dibandingkan dengan kriteria atau ambang batas yang telah ditentukan untuk mengevaluasi apakah *form push up* yang dilakukan pengguna telah sesuai dengan standar

gerakan yang ditetapkan. Form *push up* diuji menggunakan kalkulasi sudut (*angle*) yang dibentuk berdasarkan keypoint tubuh yang didapat dari MediaPipe Pose. Kalkulasi sudut dilakukan pada titik-titik keypoint tertentu yang merepresentasikan sendi utama yang berperan dalam gerakan *push up*, seperti bahu, siku, dan pinggang. Setiap sudut yang dihasilkan akan diberikan poin berdasarkan tingkat ketepatan gerakan terhadap kriteria sudut yang telah ditentukan pada Tabel 5.

Pengujian deteksi *form push up* dilakukan melalui tiga skenario berdasarkan perbedaan sudut pandang kamera, yaitu sudut depan kepala, diagonal badan dari arah pundak, dan samping badan. Contoh *frame* dari masing-masing skenario ditunjukkan pada Gambar 3, dengan Gambar 3(a) menunjukkan pengambilan video dari sudut depan, Gambar 3(b) menunjukkan pengambilan video dari sudut diagonal, dan Gambar 3(c) menunjukkan pengambilan video dari sudut samping. Penggunaan tiga sudut pandang tersebut bertujuan untuk mengevaluasi kemampuan sistem dalam mendeteksi dan menilai *form push up* ketika posisi kamera mengalami perubahan. Perbedaan sudut pengambilan video dapat menyebabkan perubahan visual terhadap posisi tubuh dan *keypoints* yang terdeteksi oleh MediaPipe Pose, sehingga pengujian ini dapat digunakan untuk mengetahui konsistensi sistem dalam memberikan hasil deteksi pada setiap sudut pandang kamera. Hasil data yang diperoleh dari pengujian ketiga skenario akan dibandingkan dan diukur berdasarkan dua luaran, yaitu *average confidence* dan poin *form*. Perbandingan *average confidence* digunakan untuk mengetahui tingkat keyakinan model dalam melakukan deteksi pada setiap sudut pandang pengambilan video. Semakin tinggi nilai *average confidence* yang diperoleh, maka semakin tinggi pula tingkat keyakinan model terhadap hasil deteksi yang dilakukan. Sementara itu, perbandingan poin *form* digunakan untuk mengevaluasi konsistensi serta mengidentifikasi kemungkinan adanya bias model dalam menilai gerakan *push up* pada sudut pandang kamera yang berbeda. Semakin kecil selisih poin *form* yang diperoleh antar skenario, maka semakin baik tingkat konsistensi sistem dalam melakukan penilaian. Pada setiap skenario pengujian digunakan video yang berisi gerakan *push up* sebanyak 10 repetisi sebagai dasar dalam membandingkan hasil deteksi dan penilaian sistem.



Gambar 3. Contoh *frame* video pengujian: (a) sudut depan, (b) sudut diagonal, dan (c) sudut samping.

4. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan dan Evaluasi Model

Model Multilayer Perceptron (MLP) dilatih menggunakan data hasil ekstraksi keypoints tubuh yang diperoleh melalui MediaPipe Pose. Data yang telah melalui tahap preprocessing kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Proses pelatihan dilakukan menggunakan MLPClassifier dari scikit-learn untuk mengklasifikasikan gerakan ke dalam tiga kelas, yaitu *ascend*, *descend*, dan *non-push up*. Hasil pelatihan dan pengujian model ditunjukkan pada Tabel 6.

Pelatihan model merupakan salah satu tahap inti dalam pembuatan model. Model yang digunakan dalam penelitian ini adalah *Multilayer Perceptron* (MLP). Proses pelatihan dilakukan dengan memanfaatkan *library MLPClassifier* dari *scikit-learn*, yang dipilih karena menyediakan implementasi MLP yang sederhana dan mudah dikonfigurasi untuk keperluan klasifikasi.

Tabel 6. *Classification Report* Pelatihan

Classification Report	Precision	Recall	F1-score	Support
Ascend	0.85	0.91	0.88	58


<https://doi.org/10.30872/atasi.v5i2.5102>

Classification Report	Precision	Recall	F1-score	Support
<i>Descend</i>	0.86	0.86	0.86	50
Non - Pushup	0.98	0.89	0.93	46
Accuracy			0.89	154
Macro Average	0.90	0.89	0.89	154
Training Accuracy			93.80 %	
Test Accuracy			88.96 %	

Berdasarkan Tabel 6, model memperoleh training accuracy sebesar 93,80% dan test accuracy sebesar 88,96%. Selisih sebesar 4,84% antara akurasi data latih dan data uji menunjukkan bahwa performa model pada data latih lebih tinggi dibandingkan data yang belum pernah digunakan selama proses pelatihan. Meskipun demikian, selisih tersebut relatif kecil sehingga model masih menunjukkan kemampuan generalisasi yang cukup baik terhadap data uji. Pada masing-masing kelas, kelas *ascend* memperoleh precision sebesar 0,85, recall sebesar 0,91, dan F1-score sebesar 0,88. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali fase naik gerakan *push up*. Kelas *descend* memperoleh precision dan recall sebesar 0,86 serta F1-score sebesar 0,86, yang menunjukkan performa relatif seimbang antara ketepatan prediksi dan kemampuan model dalam mengenali fase turun. Sementara itu, kelas *non pushup* memperoleh precision tertinggi, yaitu sebesar 0,98 dengan F1-score sebesar 0,93. Hal ini menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan gerakan *non pushup* dari kedua fase gerakan *push up*.

B. Hasil Evaluasi Per Kelas

Selain menggunakan classification report, performa model dianalisis menggunakan confusion matrix untuk mengetahui distribusi prediksi benar dan salah pada setiap kelas. Hasil confusion matrix ditunjukkan pada Gambar 4.



Gambar 4. Confusion Matrix Pengujian Model

Berdasarkan Gambar 4, sebagian besar data pada kelas *ascend*, *descend*, dan *non pushup* dapat diklasifikasikan dengan benar oleh model. Kesalahan klasifikasi lebih berpotensi terjadi antara kelas *ascend* dan *descend* karena kedua kelas tersebut merupakan bagian dari satu rangkaian gerakan *push up* dan memiliki karakteristik posisi tubuh yang relatif berdekatan, terutama pada saat terjadi transisi gerakan. Sebaliknya, kelas *non pushup* memiliki karakteristik pose yang lebih berbeda sehingga dapat dibedakan dengan lebih baik oleh model. Hasil perhitungan precision, recall, dan F1-score untuk setiap kelas ditunjukkan pada Tabel 7.

Tabel 7. Hasil Perhitungan Setiap Kelas

	Precision	Recall	F1-score
<i>Ascend</i>	85.5%	91.4%	88.3%
<i>Descend</i>	86%	88.3%	87.1%
Non - Pushup	97.6%	89.1%	93.2%

Berdasarkan Tabel 7, kelas *non pushup* memberikan performa terbaik dengan nilai precision sebesar 97,6%, recall sebesar 89,1%, dan F1-score sebesar 93,2%. Tingginya nilai precision menunjukkan bahwa ketika model memberikan prediksi *non-push up*, sebagian besar prediksi tersebut sesuai dengan kelas aktual. Kondisi ini dapat dipengaruhi oleh perbedaan karakteristik pose pada gerakan *non pushup* dibandingkan dengan fase *ascend* dan *descend*. Pada kelas *ascend*, model memperoleh precision sebesar 85,5%, recall sebesar 91,4%, dan F1-score

sebesar 88,3%. Nilai recall yang relatif tinggi menunjukkan bahwa sebagian besar data aktual *ascend* dapat dikenali dengan benar oleh model. Sementara itu, kelas *descend* memperoleh precision sebesar 86%, recall sebesar 88,3%, dan F1-score sebesar 87,1%. Hasil tersebut menunjukkan bahwa model memiliki performa yang relatif seimbang dalam mengenali ketiga kelas. Untuk memperoleh gambaran performa model secara keseluruhan tanpa dipengaruhi oleh jumlah data pada masing-masing kelas, digunakan nilai macro average. Hasil perhitungannya ditunjukkan pada Tabel 7.

Tabel 8. Hasil Macro Average Setiap Kelas

	Precision	Recall	F1-score
Macro Average	89,7%	89.6%	89.5%

Tabel 8 menunjukkan hasil pengujian menggunakan *macro average* pada data hasil pengujian *confusion matrix*. Model memperoleh nilai *macro average precision* sebesar 89,7%, yang berarti bahwa dari seluruh prediksi yang dihasilkan model pada ketiga kelas, rata-rata sebesar 89,7% merupakan prediksi yang tepat. Nilai *macro average recall* diperoleh sebesar 89,6%, yang mengindikasikan bahwa model mampu mendeteksi rata-rata 88,8% dari seluruh sampel aktual pada setiap kelas dengan benar. Adapun nilai *macro average F1-score* diperoleh sebesar 89,5%, yang mencerminkan keseimbangan yang baik antara kemampuan ketepatan prediksi dan kemampuan deteksi model secara keseluruhan.

C. Implementasi Model pada Sistem Deteksi Form Push up

Setelah melalui tahap pelatihan dan evaluasi, model kemudian diimplementasikan pada sistem deteksi form *push up* berbasis Streamlit. Sistem menerima masukan berupa video, kemudian memproses setiap frame menggunakan MediaPipe Pose untuk memperoleh koordinat keypoints tubuh. Koordinat tersebut selanjutnya dinormalisasi dan digunakan sebagai masukan bagi model MLP untuk menentukan fase gerakan yang sedang dilakukan, yaitu *ascend*, *descend*, atau *non-push up*. Selain melakukan klasifikasi fase gerakan, sistem menghitung sudut siku dan pinggang untuk melakukan penilaian terhadap form *push up*. Pengukuran menggunakan sudut pinggang dilakukan untuk mengukur kelurusan badan karena sudut pinggang dihitung berdasarkan koordinat bahu, pinggang, dan lutut, sementara sudut siku digunakan karena sudut siku sudah mencakup sendi gerakan utama *push up* karena sudut siku dihitung berdasarkan koordinat *keypoint* bahu, siku, dan pergelangan tangan. Nilai sudut tersebut kemudian dibandingkan dengan kriteria yang telah ditetapkan pada Tabel 4 untuk menghasilkan poin form pada setiap repetisi. Pengujian sistem dilakukan menggunakan tiga video gerakan *push up* yang direkam dari sudut pandang berbeda, yaitu depan, samping, dan diagonal. Ketiga video merekam rangkaian gerakan yang sama sebanyak 10 repetisi sehingga hasil penilaian dari masing-masing sudut kamera dapat dibandingkan secara langsung. Evaluasi dilakukan berdasarkan dua indikator utama, yaitu total poin form dan nilai average confidence model. Pengujian deteksi form dilakukan dengan menguji model yang telah diintegrasikan ke dalam sistem pada platform Streamlit. Pengujian menggunakan tiga video dari sudut pandang yang berbeda (depan, samping, diagonal) yang direkam secara bersamaan. Gerakan *push up* yang dilakukan sebanyak 10 repetisi. Detail perhitungan poin dapat dilihat pada Tabel 8.

Tabel 9. Detail Perhitungan Poin

Skenario	Frekuensi Poin											Total Poin
	Siku Ascend				Siku Descend				Badan			
	10	7	4	0	10	7	4	0	5	3	0	
Depan	1	9	0	0	0	0	10	0	0	10	0	143
Samping	0	1	9	0	4	6	0	0	0	10	0	155
Diagonal	10	0	0	0	1	6	3	0	0	5	5	179

Berdasarkan Tabel 9, sudut pandang diagonal menghasilkan total poin tertinggi sebesar 179 poin, diikuti oleh sudut samping sebesar 155 poin, dan sudut depan sebesar 143 poin. Hasil tersebut menunjukkan bahwa posisi kamera memberikan pengaruh terhadap hasil perhitungan sudut dan penilaian form yang dilakukan oleh sistem. Pada sudut diagonal, seluruh fase *ascend* pada 10 repetisi memperoleh poin maksimal untuk sudut siku. Hal ini menunjukkan bahwa posisi siku, bahu, dan pergelangan tangan dapat terdeteksi dengan lebih jelas dari sudut tersebut. Sudut diagonal memungkinkan perubahan posisi siku selama gerakan terlihat tanpa terlalu banyak tumpang tindih antartitik tubuh, sehingga perhitungan sudut pada fase *ascend* menjadi lebih optimal. Pada sudut samping, hasil penilaian total lebih rendah dibandingkan sudut diagonal, tetapi sudut tersebut tetap mampu menampilkan struktur tubuh secara jelas, khususnya hubungan antara bahu, pinggang, dan lutut. Sementara itu, sudut depan memperoleh total poin paling rendah. Pada posisi ini, beberapa keypoints tubuh dapat saling berdekatan atau mengalami tumpang tindih secara visual sehingga perubahan sudut sendi tidak terlihat sejelas pada pengambilan gambar dari arah samping maupun diagonal. Selain poin form, performa model juga dievaluasi berdasarkan nilai

average confidence pada fase *ascend* dan *descend* untuk setiap sudut pandang kamera. Hasil pengujian ditunjukkan pada Tabel 10.

Tabel 10. Perbandingan Average Confidence

Skenario	Class	Average Confidence
Depan	<i>Ascend</i>	49,5 %
	<i>Descend</i>	58,2 %
Samping	<i>Ascend</i>	69,6 %
	<i>Descend</i>	77,5 %
Diagonal	<i>Ascend</i>	67,1 %
	<i>Descend</i>	75,5 %

Berdasarkan Tabel 10, sudut samping memperoleh nilai *average confidence* tertinggi, yaitu 69,6% pada kelas *ascend* dan 77,5% pada kelas *descend*. Sudut diagonal memperoleh nilai yang mendekati sudut samping, yaitu sebesar 67,1% pada kelas *ascend* dan 75,5% pada kelas *descend*. Sementara itu, sudut depan menghasilkan nilai *average confidence* terendah, yaitu sebesar 49,5% pada kelas *ascend* dan 58,2% pada kelas *descend*. Hasil tersebut menunjukkan bahwa model lebih yakin dalam melakukan klasifikasi ketika posisi tubuh diamati dari arah samping dan diagonal. Dari kedua sudut tersebut, perubahan posisi tubuh antara fase *ascend* dan *descend* dapat terlihat lebih jelas, terutama pada bagian siku dan garis tubuh. Sebaliknya, pengambilan gambar dari arah depan menyebabkan perubahan kedalaman gerakan menjadi kurang terlihat pada bidang gambar dan beberapa keypoints dapat mengalami tumpang tindih, sehingga informasi yang digunakan oleh model menjadi kurang optimal. Jika hasil poin form dan *average confidence* dianalisis secara bersamaan, terdapat perbedaan karakteristik performa antara sudut diagonal dan sudut samping. Sudut diagonal menghasilkan poin form tertinggi sebesar 179, sedangkan sudut samping menghasilkan nilai *average confidence* tertinggi, yaitu 69,6% untuk *ascend* dan 77,5% untuk *descend*. Dengan demikian, tidak terdapat satu sudut pandang yang unggul pada seluruh indikator pengujian.

Tingginya poin form pada sudut diagonal menunjukkan bahwa sudut tersebut memberikan visibilitas yang baik terhadap keypoints yang digunakan dalam perhitungan sudut, khususnya bahu, siku, dan pergelangan tangan. Namun, dari sisi klasifikasi fase gerakan, model menunjukkan tingkat keyakinan yang sedikit lebih tinggi pada sudut samping. Hal tersebut mengindikasikan bahwa sudut samping menghasilkan pola koordinat keypoints yang lebih mudah dibedakan oleh model MLP antara fase *ascend* dan *descend*.

Sebaliknya, sudut depan menghasilkan nilai paling rendah pada kedua indikator. Kondisi tersebut menunjukkan bahwa sistem lebih sensitif terhadap perubahan sudut pandang kamera ketika tubuh direkam dari arah depan. Dengan demikian, berdasarkan hasil pengujian yang dilakukan, sudut samping dan diagonal merupakan sudut pengambilan video yang lebih sesuai untuk penerapan sistem dibandingkan sudut depan. Sudut diagonal memberikan hasil terbaik dalam penilaian form, sedangkan sudut samping memberikan tingkat keyakinan klasifikasi tertinggi.

5. KESIMPULAN

Berdasarkan hasil pengujian, model *Multilayer Perceptron* (MLP) yang dikembangkan berhasil memperoleh nilai akurasi uji sebesar 88,96% dan akurasi latih sebesar 93,80%, dengan kinerja yang konsisten di seluruh kelas yang ditunjukkan oleh nilai *macro average F1-score* sebesar 0,89. Sudut pandang diagonal mencatatkan performa terbaik dalam mendeteksi gerakan siku dengan raihan 179 poin, meskipun masih memiliki kekurangan pada akurasi perhitungan sudut pinggang yang memiliki selisih 10° hingga 20° lebih rendah daripada sudut pandang samping. Sementara itu, analisis *average confidence* memperkuat keunggulan sudut pandang samping yang mencetak nilai tertinggi, yaitu sebesar 69,6% untuk kelas *ascend* dan 77,5% untuk kelas *descend*, disusul oleh sudut diagonal dengan nilai yang mendekati, dan sudut depan dengan performa paling rendah.

6. DAFTAR PUSTAKA

- Arwintoro, M., Sanjaya, A., & Ramadhani, R. (2025, July 10). Deteksi Gerakan Fitness Menggunakan Pose Estimation Dan YOLOv11 . *Prosiding SEMNAS INOTEK*.
- Attar, A., Farida, I., & Swanjaya, D. (2025, July 10). Penerapan Pose Estimation dan LSTM dalam Analisis Gerakan Gym untuk Optimalisasi Teknik Latihan . *Prosiding SEMNAS INOTEK*.
- Barbieri, D., & Zaccagni, L. (2013). Strength Training for Children and Adolescents: Benefits and Risks. In *Coll. Antropol* (Vol. 37).
- Bernardo, J. S., Divinagracia, E. F., & Go, K. K. (2023). Determining Exercise Form Correctness in Real Time using Human Pose Estimation. *ACM International Conference Proceeding Series*, 83–88. <https://doi.org/10.1145/3591156.3591168>

- Bonilla, D. A., Cardozo, L. A., Vélez-Gutiérrez, J. M., Arévalo-Rodríguez, A., Vargas-Molina, S., Stout, J. R., Kreider, R. B., & Petro, J. L. (2022). Exercise Selection and Common Injuries in Fitness Centers: A Systematic Integrative Review and Practical Recommendations. In *International Journal of Environmental Research and Public Health* (Vol. 19, Number 19). MDPI. <https://doi.org/10.3390/ijerph191912710>
- Chai, J., Zeng, H., Li, A., & Ngai, E. W. T. (2021). Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6, 100134. <https://doi.org/10.1016/j.mlwa.2021.100134>
- Contreras, B., Schoenfeld, B., Mike, J., Tiriyaki-Sonmez, G., Cronin, J., & Vaino, E. (2012). The Biomechanics of the Push-up. *Strength & Conditioning Journal*, 34(5), 41–46. <https://doi.org/10.1519/SSC.0b013e31826d877b>
- Costa, T., Guerreiro, M., Puchta, E., Tadano, Y. de S., Alves, T., Kaster, M., & Siqueira, H. (2023). Multilayer Perceptron. In L. Minku, G. Cabral, M. Martins, & M. Wagner (Eds.), *Introduction to Computational Intelligence* (pp. 108–109). IEEE Computational Intelligence Society Open Book.
- Farhadpour, S., Warner, T. A., & Maxwell, A. E. (2024). Selecting and Interpreting Multiclass Loss and Accuracy Assessment Metrics for Classifications with Class Imbalance: Guidance and Best Practices. *Remote Sensing*, 16(3), 533. <https://doi.org/10.3390/rs16030533>
- Indriani, Harris, Moh., & Agoes, A. S. (2021). *Applying Hand Gesture Recognition for User Guide Application Using MediaPipe*. <https://doi.org/10.2991/aer.k.211106.017>
- Jess Fassnidge. (2025, April 23). *Strength Training*. www.scienceforsport.com/strength-training/
- Kementrian Pemuda dan Olahraga. (2024). *Laporan Indeks Pembangunan Olahraga 2024*. 92–92.
- Kowalski, K. L., Connelly, D. M., Jakobi, J. M., & Sadi, J. (2022). Shoulder electromyography activity during push-up variations: a scoping review. *Shoulder & Elbow*, 14(3), 325–339. <https://doi.org/10.1177/17585732211019373>
- Kwon, Y., & Kim, D. (2022). Real-Time Workout Posture Correction using OpenCV and MediaPipe. *The Journal of Korean Institute of Information Technology*, 20(1), 199–208. <https://doi.org/10.14801/jkiit.2022.20.1.199>
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies*, 9(4), 81. <https://doi.org/10.3390/technologies9040081>
- Mubayyin, M. T., Anantacia, E. M. A., Salsabila, C., & Hidayattullah, M. F. (2025). Klasifikasi dan deteksi pose pilates menggunakan mediapipe dan random forest classifier. *Teknosains: Media Informasi Sains Dan Teknologi*, 19(1), 56–63. <https://doi.org/10.24252/teknosains.v19i1.53698>
- Parmar, P., Gharat, A., & Rhodin, H. (2022). *Domain Knowledge-Informed Self-Supervised Representations for Workout Form Assessment*.
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- Remiro, M. Á., Gil-Martín, M., & San-Segundo, R. (2023). Improving Hand Pose Recognition Using Localization and Zoom Normalizations over MediaPipe Landmarks †. *Engineering Proceedings*, 58(1). <https://doi.org/10.3390/ecsa-10-16215>
- San Juan, J. G., Suprak, D. N., Roach, S. M., & Lyda, M. (2015). The effects of exercise type and elbow angle on vertical ground reaction force and muscle activity during a push-up plus exercise. *BMC Musculoskeletal Disorders*, 16(1), 23. <https://doi.org/10.1186/s12891-015-0486-5>
- World Health Organization. (2024). *Physical activity*. <https://www.who.int/initiatives/behealthy/physical-activity>