

# Implementasi Teknik Ekstraksi Pose dengan MediaPipe dan Klasifikasi Random Forest untuk Penentuan Kualitas Gerakan Push-Up

<sup>1\*</sup>**Riko Andriawan, <sup>2</sup>Patmi Kasih, <sup>3</sup>Danar Putra Pamungkas**

<sup>1,2,3</sup> Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: [\\*rikoadre187@gmail.com](mailto:rikoadre187@gmail.com), [2fatkasih@gmail.com](mailto:fatkasih@gmail.com), [3danar@unpkediri.ac.id](mailto:danar@unpkediri.ac.id)

*Penulis Korespondens : Riko Andriawan*

**Abstrak**— Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis terhadap gerakan *push-up* menggunakan metode ekstraksi pose MediaPipe dan klasifikasi Random Forest. Ekstraksi fitur dilakukan dengan mendeteksi 12 titik tubuh utama (bahu, siku, pergelangan tangan, pinggul, lutut, pergelangan kaki) dari setiap frame video, yang dikonversi menjadi vektor numerik. Penentuan kategori “benar” dan “salah” dilakukan berdasarkan observasi visual terhadap postur, seperti kelurusinan punggung, sudut siku, dan kestabilan tubuh, sesuai label dari sumber dataset. Data yang telah dilabeli digunakan untuk melatih model Random Forest, yang kemudian diuji dengan berbagai nilai random state. Hasil menunjukkan bahwa model memiliki akurasi tertinggi pada random state 0. Sistem ini juga dilengkapi antarmuka grafis (GUI) untuk mempermudah pengguna dalam mengunggah video dan memperoleh hasil klasifikasi secara langsung. Hasil ini berpotensi mendukung latihan kebugaran secara mandiri dan terstandar.

**Kata Kunci**— Deteksi Otomatis, Ekstraksi Pose, Klasifikasi Gerakan, *MediaPipe*, *Push-up*, *Random Forest*

**Abstract**— This study aims to develop an automatic detection system for *push-up* movements using *MediaPipe*-based pose extraction and the Random Forest classification algorithm. Feature extraction is performed by detecting 12 key body points (shoulders, elbows, wrists, hips, knees, and ankles) from each video frame and converting them into numerical vectors. The categorization of “correct” and “incorrect” *push-ups* is determined through visual observation of posture indicators such as back alignment, elbow angle, and body stability, based on labeled datasets. The labeled data is used to train the Random Forest model, which is evaluated using various random state values. Results show the highest classification accuracy is achieved with random state 0. Additionally, a graphical user interface (GUI) is developed to facilitate users in uploading videos and receiving real-time classification feedback. This system offers practical potential as a standardized tool to support self-guided fitness training.

**Keywords**— Automatic Evaluation, Pose Extraction, Movement Classification, *MediaPipe*, *Push-Up Detection*, *Random Forest*

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



## I. PENDAHULUAN

*Push-up* merupakan salah satu latihan fisik dasar yang umum dilakukan untuk melatih otot tubuh bagian atas, seperti dada, bahu, dan lengan. Meski sederhana, gerakan *push-up* yang tidak dilakukan dengan teknik yang benar dapat menimbulkan risiko cedera, khususnya pada

pergelangan tangan, bahu, dan tulang belakang. Oleh karena itu, penting memastikan setiap gerakan dilakukan dengan postur yang tepat agar manfaat latihan dapat diperoleh secara aman dan optimal [1]. Saat ini, penilaian terhadap kualitas *push-up* masih banyak dilakukan secara manual oleh pelatih atau instruktur kebugaran. Pendekatan ini sangat bergantung pada kemampuan pengamat dan cenderung subjektif, serta tidak efisien untuk skala latihan besar atau tanpa pendampingan langsung. Minimnya akurasi visual dan keterbatasan alat membuat sistem manual sulit memberikan evaluasi real-time. Hal ini memunculkan kebutuhan akan sistem evaluasi gerakan yang objektif, konsisten, dan otomatis [2], [3].

Teknologi pose estimation menawarkan solusi dengan mengekstraksi koordinat titik-titik kunci tubuh dari gambar atau video secara real-time tanpa perangkat tambahan. MediaPipe menjadi salah satu metode yang efektif untuk mendeteksi titik seperti bahu, siku, pinggul, dan lutut [4]. Data ini bersifat numerik dan dapat diolah lebih lanjut untuk menghitung sudut tubuh, postur, serta pergerakan. Dengan demikian, pose estimation sangat cocok digunakan sebagai fondasi sistem analisis kualitas gerakan olahraga seperti *push-up*. Data pose yang telah diperoleh kemudian diklasifikasikan menggunakan algoritma Random Forest. Algoritma ini dikenal memiliki akurasi tinggi, mampu menangani data berdimensi besar, serta menghindari overfitting. Dengan menggabungkan pose estimation dan Random Forest, sistem dapat mengidentifikasi gerakan *push-up* yang benar atau salah secara otomatis. Pendekatan ini juga telah berhasil digunakan dalam penelitian lain seperti deteksi bahasa isyarat atau klasifikasi teknik olahraga berbasis gerakan tubuh [5], [6], [7].

Penelitian ini bertujuan merancang sistem deteksi gerakan *push-up* berbasis kombinasi MediaPipe dan Random Forest. Sistem ini mampu mengevaluasi gerakan secara otomatis dan real-time, serta memberikan hasil klasifikasi yang akurat berdasarkan analisis frame video secara keseluruhan. Keunikan penelitian ini terletak pada pendekatan evaluasi berkelanjutan antar frame dan penerapan majority voting untuk menentukan hasil akhir. Dengan tambahan antarmuka pengguna yang interaktif, sistem ini tidak hanya unggul secara teknis tetapi juga praktis untuk mendukung latihan mandiri, pencegahan cedera, dan rehabilitasi.

## II. METODE

### A. Pengumpulan dan Pelabelan Data

Data yang digunakan dalam penelitian ini diperoleh dari situs Kaggle.com (<https://www.kaggle.com/datasets/mohamadashrafalama/pushup>), yang menyediakan dokumentasi video gerakan *push-up* yang dilakukan secara langsung oleh subjek.

Kaggle adalah komunitas daring yang didirikan pada tahun 2010 oleh Anthony Goldbloom dan Ben Hamner sebagai wadah bagi para praktisi dan penggemar data science untuk mendalami machine learning dan ilmu terkait lainnya. Selain terkenal dengan kompetisi machine learning, Kaggle juga menyediakan ruang kolaborasi untuk berbagi kode, belajar bersama, dan bahkan mendapatkan penghasilan melalui proyek-proyek tertentu. Dengan lebih dari 1000 dataset, 170.000 postingan forum, dan 250 kernel, Kaggle dikenal memiliki konten berkualitas tinggi berkat komunitasnya yang aktif. Pertumbuhannya yang pesat membuat Google mengakuisisi platform ini pada tahun 2017 [8].

Menurut Winarno (2018) dalam bukunya Evaluasi dalam Pendidikan Jasmani dan Olahraga, 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,

menjaga pernapasan tetap stabil, dan menghindari tekanan berlebih pada pergelangan tangan [9]. Sementara itu, berdasarkan Aprilo & Yasriuddin (2016) dalam penelitiannya di Universitas Negeri Makassar, kesalahan umum dalam *push-up* meliputi postur tubuh yang tidak sejajar (pinggul terlalu naik atau turun), penempatan tangan yang terlalu sempit atau terlalu lebar, serta gerakan yang terlalu cepat tanpa kontrol, sehingga mengurangi efektivitas latihan dan berisiko menimbulkan cedera [10]. Penelitian lain oleh Putra & Mukhtarsyaf (2019) juga menegaskan bahwa kesalahan teknik seperti melengkungkan punggung atau tidak menurunkan badan hingga sudut siku mencukupi, dapat berdampak negatif terhadap pencapaian hasil latihan, karena target otot tidak dilatih secara optimal [11].

Seluruh informasi di atas digunakan sebagai dasar pelabelan data dalam penelitian ini, yaitu untuk mengklasifikasikan setiap frame gerakan *push-up* ke dalam kategori "benar" atau "salah" berdasarkan postur tubuh, posisi sendi, dan kualitas gerakan sebagaimana dijelaskan dalam referensi tersebut.

#### B. Ekstraksi Ciri Berbasis Pose Estimation

Pada penelitian ini, proses ekstraksi ciri dilakukan menggunakan algoritma MediaPipe Pose yang bekerja berdasarkan metode BlazePose. Algoritma ini secara otomatis mendeteksi 33 titik kunci (*keypoints*) pada tubuh manusia, termasuk bahu, siku, pergelangan tangan, pinggul, lutut, dan mata kaki. Setiap titik diberikan koordinat dalam sistem dua dimensi (x, y), yang mewakili posisi relatif terhadap bingkai gambar/video. Setelah titik-titik tersebut terdeteksi, hanya titik-titik yang relevan dengan evaluasi gerakan *push-up* yang dipilih sebagai fitur, seperti bahu, siku, pinggul, dan lutut. Koordinat titik ini direkam untuk setiap frame dari video masukan dan dikonversi menjadi vektor numerik. Data vektor inilah yang selanjutnya digunakan sebagai masukan (input) ke dalam algoritma klasifikasi, yakni Random Forest.

Proses pelabelan dilakukan berdasarkan data video yang sudah dikategorikan sebelumnya sebagai "*push-up* benar" atau "*push-up* salah". Dengan memanfaatkan hasil ekstraksi pose dari MediaPipe, masing-masing frame dari video tersebut akan memiliki label sesuai asal video-nya. Label ini kemudian digunakan sebagai target dalam proses pelatihan model klasifikasi. Teknologi MediaPipe Pose terbukti mampu melakukan deteksi titik tubuh secara real-time dan akurat, tanpa memerlukan peralatan tambahan selain kamera. Keunggulan ini menjadikan metode ini sangat cocok untuk aplikasi monitoring gerakan tubuh secara otomatis [12].

#### C. Ekstraksi Titik Kunci Tubuh Menggunakan MediaPipe Pose

MediaPipe Pose merupakan algoritma pose estimation berbasis deep learning yang dikembangkan oleh Google, dirancang untuk melacak pose tubuh manusia secara real-time melalui gambar atau video RGB. Teknologi ini mampu mendeteksi hingga 33 titik kunci (*keypoints*) tubuh manusia, yang masing-masing mewakili bagian tubuh seperti kepala, bahu, siku, pinggul, lutut, dan pergelangan kaki. Setiap titik dilengkapi dengan koordinat tiga dimensi (x, y, z) yang merepresentasikan posisi spasial dalam satu frame video [13].

Dalam penelitian ini, tidak semua titik digunakan, hanya titik-titik yang relevan dengan gerakan *push-up* yang dipilih untuk mengurangi kompleksitas data namun tetap mempertahankan informasi penting mengenai postur tubuh. Titik-titik yang digunakan meliputi bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki, masing-masing pada sisi kanan dan kiri. Koordinat dari titik-titik ini diekstraksi dari setiap frame video dan selanjutnya

digunakan dalam proses ekstraksi fitur serta klasifikasi gerakan. Pendekatan ini memastikan efisiensi tanpa mengorbankan akurasi dalam mendeteksi gerakan *push-up*.

#### D. Proses Pelatihan Model dan Klasifikasi Gerakan *Push-up*

Pada penelitian ini, proses klasifikasi gerakan *push-up* dilakukan menggunakan algoritma Random Forest Classifier yang diimplementasikan melalui pustaka scikit-learn. Algoritma ini dipilih karena kemampuannya menangani data berdimensi tinggi serta ketahanannya terhadap overfitting. Model bekerja dengan membangun sejumlah pohon keputusan (decision tree) dari berbagai subset acak data latih dan fitur yang diekstraksi dari koordinat titik-titik kunci tubuh seperti bahu, siku, pinggul, lutut, dan pergelangan kaki yang diambil dari setiap frame video menggunakan MediaPipe Pose. Setiap pohon melakukan klasifikasi independen, dan hasil akhirnya ditentukan berdasarkan majority voting dari seluruh pohon.

Meskipun hasil klasifikasi yang dihasilkan oleh model Random Forest hanya *push-up* salah dan *push-up* benar namun data yang digunakan sebagai input pada proses klasifikasi adalah data numerik kontinu. Data ini berasal dari proses ekstraksi fitur, di mana setiap frame video dievaluasi menggunakan algoritma pose estimation (MediaPipe) untuk mendapatkan koordinat titik-titik tubuh penting, seperti bahu, siku, pinggul, lutut, dan pergelangan kaki. Setiap titik terdiri dari koordinat X dan Y dalam dimensi normalisasi video, yang membentuk vektor fitur berdimensi tinggi, misalnya  $[x_1, y_1, x_2, y_2, \dots, x_n, y_n]$ .

Vektor fitur ini tidak memiliki label intrinsik (belum "benar" atau "salah"), tetapi mewakili postur tubuh pada suatu frame. Model Random Forest memproses vektor ini dengan cara membandingkan pola-pola koordinat tersebut terhadap data latih yang sudah memiliki label. Berdasarkan kedekatan atau pola fitur yang dikenali selama pelatihan, model kemudian memutuskan apakah postur yang dianalisis sesuai dengan kategori *push-up* benar atau salah. Artinya, model tidak langsung "melihat" label benar atau salah, tetapi membuat keputusan berdasarkan pola angka-angka (koordinat) yang mewakili bentuk tubuh manusia dalam pose tertentu. Oleh karena itu, klasifikasi dilakukan dari data numerik menjadi keputusan kategorikal. Dengan pendekatan ini, model tidak hanya sekadar menghitung posisi satu titik, tetapi mempertimbangkan pola hubungan antar titik seperti sudut lengan terhadap badan, posisi bahu terhadap pinggul, dan sebagainya semua dikodekan secara tidak langsung dalam kombinasi nilai koordinat. Inilah yang memungkinkan model Random Forest melakukan klasifikasi gerakan dengan mempertimbangkan konteks postur tubuh secara menyeluruh.

Proses pelatihan dilakukan dengan membagi dataset menjadi 80% data latih dan 20% data uji. Model dikonfigurasi menggunakan parameter `n_estimators` = 0 dan beberapa nilai `random_state` (0, 45, dan 100) untuk memperoleh hasil akurasi terbaik. Keluaran klasifikasi dibagi menjadi dua label, "Benar" untuk postur yang sesuai seperti tubuh lurus dan sudut siku mendekati 90 derajat, dan "Salah" untuk postur yang tidak sesuai seperti punggung melengkung atau kepala tidak sejajar. Setelah pelatihan selesai, model disimpan dalam format `.pkl` menggunakan pustaka joblib untuk digunakan pada tahap inferensi. Sistem kemudian mengklasifikasikan setiap frame dalam video dan menentukan label akhir berdasarkan mayoritas prediksi, sehingga memungkinkan evaluasi gerakan *push-up* secara otomatis dan akurat.

#### E. Evaluasi Model

Dalam evaluasi sistem, digunakan metrik akurasi serta Confusion Matrix untuk menilai kinerja klasifikasi. Selain itu, sistem turut menghitung jumlah frame yang berhasil dikenali sebagai pose, serta mengevaluasi konsistensi prediksi antar frame dalam satu video. Hasil akhir klasifikasi kemudian ditentukan berdasarkan mayoritas prediksi dari seluruh frame yang dianalisis dalam video tersebut.

Confusion Matrix merupakan alat evaluasi performa model klasifikasi yang disajikan dalam bentuk tabel, membandingkan hasil prediksi model dengan label sebenarnya dari data uji. Matriks ini terdiri dari empat komponen utama, yaitu *True Positive (TP)* yang menunjukkan prediksi benar untuk kelas positif, *True Negative (TN)* untuk prediksi benar pada kelas negatif, *False Positive (FP)* saat model salah memprediksi sebagai positif padahal sebenarnya negatif, dan *False Negative (FN)* ketika model memprediksi sebagai negatif padahal sebenarnya positif. Confusion Matrix juga menjadi dasar dalam perhitungan berbagai metrik evaluasi seperti akurasi, presisi, recall, dan F1-score [14].

#### F. Implementasi Sistem

Sistem ini dirancang dalam bentuk antarmuka grafis (GUI) dengan memanfaatkan bahasa pemrograman Python dan pustaka Tkinter. Pengguna dapat berinteraksi dengan sistem secara visual, mulai dari proses unggah video hingga melihat hasil klasifikasi. Alur kerja sistem terdiri dari beberapa tahap, dimulai dari pengunggahan video oleh pengguna hingga tampilan hasil prediksi yang disajikan dalam bentuk pop-up. Setiap langkah diproses secara otomatis oleh sistem, termasuk pemutaran video, ekstraksi pose dari setiap frame, klasifikasi gerakan *push-up*, dan penentuan label akhir berdasarkan mayoritas label dari seluruh frame. Lebih jelas alur sistem di paparkan pada gambar 1.

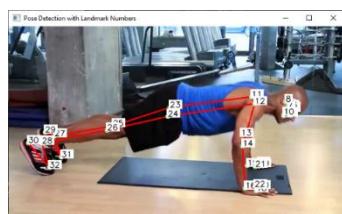


Gambar 1. Alur Sistem

### III. HASIL DAN PEMBAHASAN

#### A. Ekstraksi Fitur Deteksi Pose

Proses ekstraksi fitur pada penelitian ini menggunakan MediaPipe Pose, framework pose estimation real-time dari Google yang mampu mendekripsi hingga 33 titik kunci (*keypoints*) tubuh manusia dari citra atau video. Setiap titik direpresentasikan dalam koordinat (x, y) yang menunjukkan posisi relatif dalam bidang gambar. Namun, untuk keperluan klasifikasi gerakan *push-up*, hanya 12 titik kunci yang dianggap relevan dan digunakan, yaitu bahu, siku, pergelangan tangan, pinggul, lutut, dan pergelangan kaki kanan dan kiri (index 11–16 dan 23–28). Pemilihan subset ini bertujuan untuk mengurangi dimensi data sambil tetap mempertahankan informasi postural yang esensial.



Gambar 2. Deteksi Pose

Gambar 2 menunjukkan nilai koordinat. Dengan nilai koordinat per titik, setiap frame menghasilkan vektor fitur berdimensi 24 yang selanjutnya digunakan sebagai input bagi algoritma Random Forest dalam proses klasifikasi. Hasil ekstraksi pose ini dapat divisualisasikan dengan menampilkan overlay skeleton pada frame video, yang membantu memverifikasi keberhasilan sistem dalam mendeteksi postur tubuh secara akurat, sebagaimana ditunjukkan pada Gambar 2.

#### B. Proses Pelabelan Video Gerakan *Push-up*

Dalam proses pelatihan dan pengujian model klasifikasi, setiap video gerakan *push-up* yang digunakan berasal dari dataset yang diunduh melalui platform Kaggle, di mana seluruh video telah diberi label “benar” atau “salah” oleh penyusun dataset. Label tersebut disusun berdasarkan pengamatan visual yang mengacu pada deskripsi postur dan teknik gerakan dalam metadata dataset. Untuk memastikan kesesuaian, dilakukan peninjauan ulang terhadap setiap video guna memastikan bahwa label yang diberikan mencerminkan kualitas gerakan secara akurat.

Gerakan *push-up* dikategorikan sebagai “benar” apabila menunjukkan postur tubuh yang stabil dan sesuai, seperti tubuh membentuk garis lurus dari kepala hingga kaki, siku menekuk hingga hampir 90 derajat saat menurun, posisi tangan sejajar bahu, serta tidak terdapat kelengkungan pada punggung atau pinggul. Selain itu, gerakan dilakukan secara simetris dan terkendali. Sebaliknya, jika gerakan menunjukkan kesalahan teknis seperti posisi pinggul tidak sejajar, tangan terlalu sempit/lebar, siku kurang menekuk, atau gerakan tidak stabil, maka diklasifikasikan sebagai “salah”. Penentuan label dilakukan berdasarkan penilaian terhadap keseluruhan rangkaian gerakan dalam video, bukan hanya pada satu frame, untuk menjaga konsistensi dan objektivitas proses pelabelan.

#### C. Evaluasi Kinerja Model Random Forest

Model klasifikasi yang digunakan dalam penelitian ini adalah Random Forest Classifier, sebuah algoritma berbasis ensemble learning yang bekerja dengan mengombinasikan sejumlah pohon keputusan (decision tree) untuk meningkatkan tingkat akurasi sekaligus meminimalkan risiko overfitting. Pelatihan model dilakukan menggunakan fitur-fitur yang diperoleh dari hasil ekstraksi pose tubuh manusia pada video *push-up*, di mana setiap video telah diberi label “benar” atau “salah”.

Data yang digunakan berasal dari pemrosesan video yang dikonversi menjadi fitur per frame, lalu dibagi menjadi data latih dan data uji dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Parameter yang diterapkan pada model antara lain `n_estimators` sebanyak 100 pohon dan `random_state` sebesar 0, berdasarkan hasil pengujian parameter terbaik. Kinerja model terhadap data uji dirangkum dan disajikan dalam Tabel 1.

Tabel 1. Evaluasi Kinerja Random Forest

Kelas	Precision	Recall	F1-Score
Benar	0,91	1,00	0,95
Salah	1,00	0,90	0,95

Mengacu pada Tabel 1, model berhasil memperoleh akurasi total sebesar 95%. Tingginya nilai precision dan recall pada kedua kelas mengindikasikan bahwa model mampu

mengklasifikasikan gerakan *push-up* benar maupun salah secara seimbang dan menunjukkan performa yang baik.

#### D. Uji Eksperimen pada Video Input

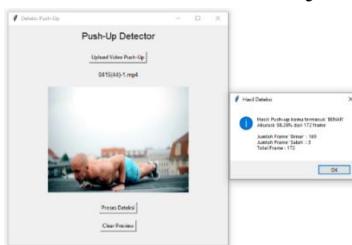
Setelah model Random Forest dilatih menggunakan dataset hasil ekstraksi pose, tahap selanjutnya adalah mengembangkan sistem deteksi berbasis antarmuka pengguna (GUI) dengan menggunakan bahasa pemrograman Python dan pustaka Tkinter. Sistem ini dirancang agar pengguna dapat dengan mudah mengunggah video *push-up*, melihat pratinjau video, menjalankan proses ekstraksi pose, melakukan klasifikasi gerakan per frame, serta menampilkan hasil akhir berupa label *push-up* benar atau salah beserta tingkat akurasinya.

Pengujian sistem dilakukan dengan mengunggah berbagai video yang menampilkan gerakan *push-up*, baik dengan teknik yang benar maupun salah. Sistem kemudian memproses setiap frame, memprediksi label pada masing-masing frame, dan menghitung jumlah prediksi untuk tiap kategori. Penentuan label akhir dilakukan dengan metode majority voting berdasarkan hasil prediksi seluruh frame. Hasil lengkap dari proses pengujian ini disajikan pada Tabel 2.

Tabel 2. Uji Eksperimen Vidio Input

Nama Vidio	Total Frame	Prediksi "Benar"	Prediksi "Salah"	Label Akhir	Akurasi (%)
Push-up 38.mp4	63	34	29	Benar	53,97
0415(44)-1.mp4	172	169	3	Benar	98,2
10xx.mp4	205	2	203	Salah	99,02
17.mp4	107	0	107	Salah	100%

Berdasarkan hasil pengujian pada Tabel 2, sistem menunjukkan performa yang bervariasi tergantung pada kualitas gerakan dalam video. Pada video *Push-up* 38.mp4, akurasi rendah sebesar 53,97% mengindikasikan adanya ketidakstabilitan gerakan, sedangkan pada video 0415(44)-1.mp4, akurasi tinggi 98,2% menunjukkan gerakan yang stabil dan sesuai pola pelatihan. Untuk video 10xx.mp4 dan 17.mp4 yang berisi *push-up* salah, sistem berhasil mendeteksi dengan akurasi sangat tinggi, masing-masing 99,02% dan 100%. Hasil ini membuktikan efektivitas model Random Forest berbasis pose estimation dalam membedakan *push-up* benar dan salah. Tampilan antarmuka sistem ditunjukkan pada Gambar 3.



Gambar 3. UI Sistem

Gambar 3 menunjukkan tampilan antarmuka sistem deteksi *push-up* berbasis pose estimation. Pada tampilan ini, pengguna dapat mengunggah video *push-up*, melihat pratinjau video, memproses video untuk mendeteksi pose, serta memperoleh hasil klasifikasi berupa label "*push-up* benar" atau "*push-up* salah" lengkap dengan informasi akurasi, jumlah frame benar, dan jumlah frame salah. Antarmuka ini dirancang sederhana untuk memudahkan interaksi pengguna selama proses pengujian.

#### E. Analisis Pengaruh Random State pada Kinerja Model

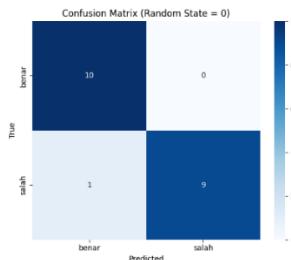
Dalam penelitian ini, dilakukan analisis terhadap pengaruh nilai `random_state` pada proses pelatihan model Random Forest. Parameter `random_state` digunakan untuk menjamin konsistensi dalam pembagian data latih dan uji pada fungsi `train_test_split`. Variasi nilai `random_state` dapat menghasilkan komposisi data uji yang berbeda, yang pada akhirnya dapat memengaruhi hasil pelatihan dan evaluasi model. Percobaan dilakukan dengan menggunakan beberapa nilai `random_state`, yaitu: 0, 45, dan 100. Hasil evaluasi akurasi dari masing-masing konfigurasi disajikan pada Tabel 3.

Tabel 3. Analisis `Random_state`

Random_State	Akurasi (%)	Keterangan
0	95	Akurasi tertinggi
45	85	Akurasi menurun
100	85	Akurasi stabil

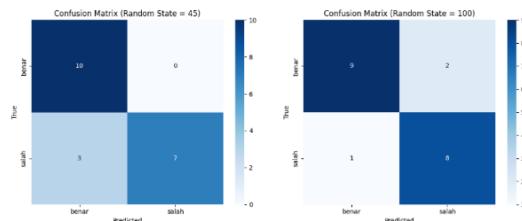
Berdasarkan hasil pada Tabel 3, diketahui bahwa nilai `random_state=0` memberikan performa terbaik dengan akurasi sebesar 95%. Hal ini menunjukkan bahwa komposisi data latih dan uji yang dihasilkan pada `seed 0` memberikan pemisahan data yang optimal, sehingga model mampu belajar pola data dengan lebih baik.

Sebagai tambahan, visualisasi *confusion matrix* dari model terbaik ditampilkan pada Gambar 4, yang menunjukkan distribusi prediksi terhadap label sebenarnya. Berdasarkan grafik tersebut, terlihat bahwa model mampu mengklasifikasikan label “benar” dan “salah” dengan cukup baik, ditunjukkan oleh jumlah prediksi tepat yang tinggi pada diagonal utama.



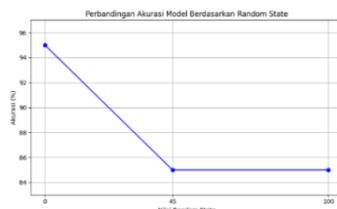
Gambar 4. Confusion matrix `random_state=0`

Analisis ini juga menegaskan pentingnya pemilihan parameter `random_state` dalam pelatihan model berbasis pembagian data acak. Meskipun perbedaan akurasi tidak terlalu signifikan, eksperimen ini membuktikan bahwa hasil pelatihan model Random Forest tidak selalu konsisten tanpa penetapan seed tertentu, sehingga perlu diuji beberapa nilai untuk mendapatkan performa yang optimal. Mengenai visualisasi *confusion matrix* untuk `random_state` 45 dan 100 ditunjukkan pada gambar 5.



Gambar 5. Confusion matrix `random_state` 45 dan 100

Dari hasil visualisasi pada Gambar 5, terlihat bahwa variasi random state menghasilkan distribusi prediksi yang sedikit berbeda. Model dengan random state 45 dan 100 memiliki kesalahan klasifikasi sedikit lebih tinggi dibandingkan model dengan seed 0. Hal ini menunjukkan bahwa meskipun model Random Forest memiliki toleransi terhadap overfitting, performa akhir masih dapat dipengaruhi oleh pembagian data latih dan uji secara acak. Pada gambar 6 akan memvisualisasikan Grafik perbandingan akurasi vs random state.



Gambar 6. Perbandingan Akurasi vs random\_state

Gambar 6 menunjukkan fluktuasi akurasi model terhadap perubahan nilai random state. Nilai random\_state = 0 menghasilkan akurasi tertinggi (95%), diikuti oleh random\_state = 42 dan random\_state = 100 menunjukkan performa yang lebih rendah.

#### IV. KESIMPULAN

Penelitian ini berhasil merancang sistem deteksi gerakan *push-up* berbasis ekstraksi pose tubuh manusia dengan memanfaatkan algoritma Random Forest. Proses ekstraksi dilakukan menggunakan MediaPipe Pose, yang secara efisien mendekripsi titik-titik kunci tubuh (*keypoints*) dari setiap frame video, kemudian mengubahnya menjadi fitur numerik berdimensi rendah namun informatif. Hasil pengujian menunjukkan bahwa sistem mampu mengklasifikasikan gerakan *push-up* benar dan salah dengan akurasi yang cukup tinggi, terutama pada model dengan nilai random state 0. Selain itu, penerapan antarmuka sederhana menggunakan Tkinter turut mempermudah pengguna dalam mengunggah video, menjalankan proses deteksi, dan menerima hasil klasifikasi secara langsung.

Walaupun performa sistem sudah baik, masih terdapat ruang untuk pengembangan ke depannya, seperti penerapan model pembelajaran sekuensial guna meningkatkan akurasi pada gerakan yang lebih dinamis, memperluas cakupan klasifikasi ke berbagai cabang olahraga lain, serta mengintegrasikan sistem ke aplikasi mobile berbasis Android. Dengan pengembangan lebih lanjut, sistem ini memiliki potensi besar untuk menjadi alat bantu latihan mandiri yang praktis, terjangkau, dan akurat.

#### DAFTAR PUSTAKA

- [1] A. Muzakir, “Rancang Bangun Aplikasi Push up Detector Untuk Mendekripsi Kesalahan Gerakan Push up,” *Annu. Res. Semin. Comput. Sci. ICT*, 2016.
- [2] A. L. Kalua, J. R. Kaplale, N. Klarissa, R. Mapalie, dan J. K. Unsrat, “PENGEMBANGAN ALAT TES KESAMAPTAAN TNI / POLRI BERBASIS TEKNOLOGI COMPUTER VISION DAN IOT DENGAN METODE POSE,” vol. XIII, no. 2, hal. 294–299, 2024.
- [3] A. Z. M Kumroni Makmuri, “PENERAPAN METODEQUALITY FUNCTION DEPLOYMENT (QFD) PADA PENGEMBANGAN PRODUKLOCKER,” hal. 1–23, 2016.

- [4] V. N. U. R. Rahmawati, “KLASIFIKASI GERAKAN PENCAK SILAT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS BODY POSE,” INSTITUT TEKNOLOGI SEPULUH NOPEMBER SURABAYA, 2023. [Daring]. Tersedia pada: [https://repository.its.ac.id/99417/2/07111950050005-Master\\_Thesis.pdf](https://repository.its.ac.id/99417/2/07111950050005-Master_Thesis.pdf)
- [5] S. A. Kaffah dan Y. Ramdhani, “Gesture Recognition untuk Deteksi Bahasa Isyarat BISINDO: Pendekatan Mediapipe dan Random Forest,” *JOINTECS (Journal Inf. Technol. Comput. Sci.)*, vol. 8, no. 3, hal. 105, 2023, doi: 10.31328/jointecs.v8i3.4813.
- [6] H. Diki Taufi, “Human Motion Detection Untuk Terjemah Bahasa Isyarat Menggunakan Metode Random Forest Skripsi,” UNIVERSITAS MUHAMMADIYAH MALANG, 2023. [Daring]. Tersedia pada: <https://eprints.umm.ac.id/id/eprint/946/1/PENDAHULUAN.pdf>
- [7] A. B. Rizki dan E. Zuliarso, “Klasifikasi Teknik Bulutangkis Berdasarkan Pose Dengan Convulutional Neural Network,” *J. Ilm. Inform.*, vol. 10, no. 02, hal. 96–101, 2022, doi: 10.33884/jif.v10i02.5559.
- [8] N. Rahmalia, “Kaggle , Komunitas Belajar Data Science yang Bisa Jadi Sumber Uang Apa Itu Kaggle ?” Diakses: 23 April 2025. [Daring]. Tersedia pada: <https://glints.com/id/lowongan/kaggle-adalah/>
- [9] M. P. Dr. M.E. Winarno, *EVALUASI DALAM PENDIDIKAN JASMANI DAN OLAHRAGA*. JAKARTA: CENTER FOR HUMAN CAPACITY DEVELOPMENT, 2004. [Daring]. Tersedia pada: <https://fik.um.ac.id/wp-content/uploads/2018/02/buku-5.pdf>
- [10] I. Aprilo dan Yasriuddin, “Studi Awal Pengembangan Instrumen Tes Push Up Berbasis It,” *J. Il.*, vol. VII, no. 2, hal. 1–107, 2016.
- [11] J. Naldi, “Pengaruh Latihan *Push-up* Terhadap Kemampuan Volley Atlet Tenis Lapangan PTL UNP,” vol. 4, hal. 11587–11599, 2024, [Daring]. Tersedia pada: [http://repository.unp.ac.id/3602/1/02\\_A\\_FADLI\\_MUKHTAR\\_85562\\_1479\\_2012.pdf](http://repository.unp.ac.id/3602/1/02_A_FADLI_MUKHTAR_85562_1479_2012.pdf)
- [12] C. Lugaressi *et al.*, “MediaPipe: A Framework for Building Perception Pipelines,” 2019, [Daring]. Tersedia pada: <http://arxiv.org/abs/1906.08172>
- [13] R. Arlin dan R. Munir, “Thesis The Development of Push Up Counter Android Application with Computer Vision,” 2023.
- [14] N. B. Putri dan A. W. Wijayanto, “Analisis Komparasi Algoritma Klasifikasi Data Mining Dalam Klasifikasi Website Phishing Comparative Analysis Of Data Mining Classification Algorithm In Phishing Website Classification,” vol. 11, no. 28, hal. 59–66, 2022, doi: 10.34010/komputika.v11i1.4350.