

# Identifikasi Biometrik Gaya Berjalan Penyandang Disabilitas Menggunakan KNN

<sup>1\*</sup>**Pramudya Cipta Panataagama, <sup>2</sup>Resty Wulanningrum, <sup>3</sup>Siti Rochana**

<sup>1</sup> Teknik Informatika Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: <sup>1</sup>nata99.gama@gmail.com, <sup>2</sup>restyw@unpkdr.ac.id, <sup>3</sup> sitirochana@unpkediri.ac.id

**Penulis Korespondens : Pramudya Cipta Panatagama**

**Abstrak**— Analisis gaya berjalan pada anak disabilitas penting untuk mendeteksi gangguan motorik dan merancang intervensi rehabilitasi yang tepat. Metode konvensional seperti sensor *wearable* atau sistem kamera 3D mahal dan terbatas penggunaannya. Penelitian ini mengusulkan sistem klasifikasi pola berjalan berbasis *MediaPipe Pose* dan algoritma *K-Nearest Neighbor* untuk identifikasi gaya berjalan normal, disabilitas tanpa tongkat, dan disabilitas dengan tongkat. Data diambil dari dataset terbuka dan diolah melalui ekstraksi fitur dari 22 titik tubuh bagian atas dan bawah. Sistem diuji menggunakan pembagian data pelatihan dan pengujian dengan rasio 80:20. Hasil menunjukkan akurasi tinggi dalam klasifikasi, menunjukkan efektivitas pendekatan non-invasif ini. Penelitian ini memberikan kontribusi bagi pengembangan sistem pemantauan rehabilitasi yang lebih murah dan mudah diimplementasikan.

**Kata Kunci**— Disabilitas, gaya berjalan, KNN, *MediaPipe*, pengenalan pola.

**Abstract**— *Gait analysis in children with disabilities is essential for detecting motor impairments and designing appropriate rehabilitation interventions. Conventional methods such as wearable sensors or 3D camera systems are costly and limited in use. This study proposes a gait classification system based on MediaPipe Pose and the K-Nearest Neighbor algorithm to identify normal, disabled without cane, and disabled with cane walking patterns. Data were sourced from an open dataset and processed through feature extraction from 22 upper and lower body points. The system was tested using an 80 to 20 ratio of training and testing data. Results showed high classification accuracy, proving the effectiveness of this non-invasive approach. This study contributes to the development of low-cost and easily deployable rehabilitation monitoring systems.*

**Keywords**— Disability, gait analysis, KNN, *MediaPipe*, pattern recognition

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



## I. PENDAHULUAN

Analisis gaya berjalan (*gait analysis*) pada anak disabilitas merupakan aspek kritis dalam evaluasi perkembangan motorik dan intervensi rehabilitasi. Metode konvensional seperti sistem *Vicon* [1] dan platform gaya reaksi tanah (*force plate*) [2] memiliki akurasi tinggi tetapi terbatas pada lingkungan klinis dengan biaya mahal dan kompleksitas operasional. Perkembangan *pose estimation* berbasis *deep learning* seperti *MediaPipe Pose* [3] dan *OpenPose* [4] memungkinkan analisis gerak secara *markerless* dengan kamera standar, namun implementasinya pada populasi pediatrik dengan variasi pola berjalan atipikal masih terbatas [5].

Studi terbaru menunjukkan potensi kombinasi *pose estimation* dengan algoritma klasifikasi seperti KNN untuk identifikasi abnormalitas gerak. Misalnya, Putra (2020) berhasil mendeteksi gerakan raket bulutangkis dengan akurasi 85% menggunakan KNN [6], sementara Hii et al. (2023) membuktikan keandalan MediaPipe Pose dalam analisis gaya berjalan frontal dengan MAE 0.30 [7]. Namun, penelitian pada anak disabilitas masih mengandalkan sensor wearable invasif [8] atau dataset terbatas [9]. Kesenjangan ini memotivasi pengembangan sistem non-invasif berbasis *smartphone* yang mengintegrasikan MediaPipe untuk ekstraksi fitur kinematik dan KNN untuk klasifikasi pola berjalan disabilitas.

## II. METODE

Penelitian ini dirancang untuk mengembangkan sistem klasifikasi pola berjalan menggunakan pendekatan komputasional berbasis *machine learning*. Metode yang dipilih adalah *K-Nearest Neighbor* (KNN) karena kemampuannya dalam menangani data non-linear dan kemudahan implementasinya untuk klasifikasi berbasis jarak [7]. Dataset yang digunakan berasal dari Kaggle dengan judul "*DisabledGait: Gait Dataset of Normal People and People with Disabilities*", yang mencakup rekaman video individu dengan pola berjalan normal dan disabilitas [7].

Proses penelitian mengikuti alur standar *machine learning*, dimulai dari akuisisi data, prapemrosesan, ekstraksi fitur, pelatihan model, hingga evaluasi kinerja. Desain penelitian ini bersifat eksperimental dengan pendekatan kuantitatif untuk mengukur akurasi sistem dalam mengklasifikasikan pola berjalan.

### 1. Input Data

Sistem dirancang untuk menerima input data melalui dua mode:

a. Kamera Realtime:

Menggunakan perangkat kamera eksternal/webcam dengan resolusi standar  $640 \times 480$  piksel dan kecepatan akuisisi 30 frame per detik (fps). Sistem mengimplementasikan adaptive frame sampling untuk menjaga konsistensi temporal, bahkan pada kondisi pencahayaan rendah. Mekanisme multithreading dioptimalkan dengan double buffering untuk memisahkan proses akuisisi frame dan analisis, mengurangi latency hingga kurang 40 ms.

b. Unggah Video:

Mendukung format MP4 (H.264), AVI, dan MOV dengan resolusi hingga 1080p. Sistem secara otomatis melakukan resampling temporal untuk menyamakan frame rate video input ke 30 fps menggunakan interpolasi linear, menghindari ketidaksesuaian temporal dengan model. Memory mapping diterapkan untuk video berukuran besar lebih 500 MB guna mengurangi beban RAM.

c. Dataset

Dalam penelitian ini, digunakan dataset yang diperoleh dari platform Mandely, yang dikenal sebagai sumber data terbuka untuk berbagai keperluan penelitian. Salah satu dataset yang dimanfaatkan berjudul "*DissabledGait: Gait Dataset of Normal People and People with Disabilities*." Dataset tersebut disusun oleh Resty Wulanningrum, Anik Nur Handayani, dan Heru Wahyu Herwanto, dengan tujuan utama mendukung studi mengenai analisis pola berjalan, baik pada individu dengan gaya berjalan

normal maupun yang mengalami gangguan disabilitas. Data yang tersedia meliputi rekaman video serta hasil ekstraksi pose gerakan tubuh, yang sangat bermanfaat untuk proses klasifikasi, prediksi, dan analisis lebih lanjut. Dalam implementasinya, dataset ini telah disesuaikan terlebih dahulu melalui beberapa tahapan prapemrosesan, seperti normalisasi koordinat pose serta penyesuaian jumlah frame agar sejalan dengan sistem input yang bekerja pada kecepatan 30 frame per detik. Penyesuaian ini penting untuk menjaga konsistensi antara data latih dan data uji, terutama dalam konteks pemrosesan temporal.

## 2. Ekstraksi Fitur Pose (*Keypoint Detection*)

Penelitian ini menggunakan titik-titik tubuh (keypoints) dari MediaPipe Pose yang merepresentasikan posisi dan pergerakan anggota tubuh manusia. Total terdapat 33 titik yang tersedia dalam sistem



*Gambar 1 Keypoint Detection*

MediaPipe, namun penelitian ini hanya menggunakan titik ke 11 hingga ke 32 (yaitu total 22 titik), yang mencakup anggota tubuh bagian atas (tanpa kepala) hingga bagian bawah tubuh. Penghilangan titik kepala (titik 0 hingga 10) dilakukan dengan alasan penting, yaitu:

- Setiap Vidio dari kagle bagian area kepala tidak terlihat yang berguna agar melindungi privasi.
- Waktu digunakan penuh 33 titik bergerak tidak normal karena sulit untuk mendeteksi bagian kepalanya.

## 3. Preprocessing dan konversi data

Tahapan ini meliputi normalisasi koordinat, penghapusan titik yang tidak relevan, serta pelabelan data. Dalam penelitian ini bagian area wajah tidak di deteksi karena dalam dataset

ini mengandung privasi. Dengan mematikan pendekripsi di bagian wajah dapat mengurangi kesalahan dalam pendekripsi cara berjalan.

*Tabel 1 Tabel Tubuh Dari Keypoint*

<b>Landn</b>		<b>Table Tubuh</b>
<b>mark</b>	<b>Deskripsi</b>	<b>Koordubat (x,y,z)</b>
11	Bahu kanan	0.65, 0.72, 0.51
12	Bahu kiri	0.35,0.70,0.49
25	Lutut kanan	0.66, 0.45, 0.30
..	...	..., ..., ..., ...,
32	Ujung kaki kanan	0.55,0.44, 0.25

- a) Bahu kiri (landmark 12), bahu kanan (landmark 11).
- b) Lutut kiri (landmark 26), lutut kanan (landmark 25).

Output berupa koordinat x, y, z yang dinormalisasi menggunakan rumus:

$$\text{normalized feature} = \frac{f - f_{min}}{f_{max} - f_{min}} \quad (1)$$

Dengan menggunakan Graph Convolutional Networks (GCN) untuk memodelkan hubungan spasial antar sendi.

- a. Landmark tubuh yang telah dideteksi diubah menjadi fitur numerik. Misalnya, jarak antara bahu kiri dan kanan dihitung menggunakan rumus Euclidean:

$$d(p, q) = \sqrt{\sum_{i=1}^n (qi - pi)^2} \quad (2)$$

- b. Pelatihan Model KNN:

Model dilatih dengan data pelatihan menggunakan nilai k=3 (3 tetangga terdekat). Pemilihan k didasarkan pada percobaan awal untuk meminimalkan *overfitting*.

#### 4. Pelatihan dan Pengujian Model KNN

Fitur yang telah diperoleh dari titik-titik tubuh (keypoints) pada frame video diproses sebagai input dalam klasifikasi gaya berjalan normal, disabilitas tanpa tongkat, disabilitas dengan tongkat. menggunakan algoritma K-Nearest Neighbor (KNN). KNN bekerja dengan menghitung jarak antara data uji dan data latih, lalu menentukan kelas berdasarkan mayoritas dari k tetangga terdekat.

Implementasi KNN dilakukan menggunakan pustaka Scikit-learn (sklearn), dengan proses sebagai berikut:

- a. Setiap frame menghasilkan 22 titik (keypoints) dari tubuh bagian atas dan bawah (indeks 11–32). Masing-masing titik memiliki nilai koordinat x, y, dan z sehingga total fitur per frame:

$$Jumlah\ fitur = 22\ titik \times 3\ koordinat = 66\ fitur \quad (3)$$

b. Pembagian Data

Dataset dibagi menjadi data latih (training set) dan data uji (testing set), dengan perbandingan 80:20

c. Perhitungan Jarak Euclidean

Algoritma KNN menghitung jarak **Euclidean** antara vektor fitur data uji dan data latih:

$$d = \sqrt{(x_1 - x_1')^2 + (x_2 - x_2')^2 + \dots + (x_n - x_n')^2} \quad (4)$$

Dengan:

$X_{x_1}, x_2, \dots, X_n$  = fitur data uji

$X_{x_1}, x_2, \dots, X_n'$  = fitur data latih

d. Penentuan klasifikasi

Nilai k ditentukan berdasarkan eksperimen awal, misalnya:

$$k=3$$

Kemudian sistem menghitung jarak ke semua data latih, memilih 3 tetangga terdekat, dan menentukan kelas terbanyak (misalnya: 2 disabilitas dan 1 normal hasil adalah disabilitas).

## 5. Evaluasi dan Validasi Model

Sistem divalidasi menggunakan metrik evaluasi seperti akurasi, presisi, dan recall untuk menilai kinerja klasifikasi pola berjalan antara orang normal dan disabilitas. Ketiga metrik ini dihitung berdasarkan hasil prediksi dari model terhadap data uji.

a. Akurasi

mengukur seberapa banyak prediksi model yang benar dari seluruh data uji:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

b. Presisi

mengukur ketepatan prediksi positif dari model

$$Presisi = \frac{TP}{TP+FP} \quad (6)$$

c. Recall

mengukur seberapa banyak data positif yang berhasil dikenali oleh model:

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

d. F1

Mengukur keseimbangan antara presisi dan recall dalam sebuah model klasifikasi

$$F1 - Score = \frac{Presisi \times Recall}{Presisi + Recall} \quad (8)$$

Model diuji dengan data pengujian, dan kinerjanya diukur menggunakan:  
Akurasi: Persentase Prediksi benar dari total data uji.

$$Akurasi (k) = \frac{Jumlah Prediksi Benar}{Jumlah Total Pengujian} \times 100\% \quad (9)$$

Contoh:

*Tabel 2 Tabel Contoh Prediksi*

No.	Prediksi	
	Deskripsi	Terdeteksi / Frame
1	Total Frame	135
2	Gaya Normal	2
3	Dengan Tongkat	3
4	Tanpa Tongkat	100

Dari hasil klasifikasi didapatkan hasil total frame 135, gaya normal pada fram terdeteksi 2 frame, dengan tongkat didapatkan frame 3 , dan tanpa tongkat 100 frame. Dengan perhitungan akurasi sebagai berikut.

$$\text{Maka: } Akurasi (k) = \frac{Jumlah Prediksi Benar}{Jumlah Total Pengujian} \times 100\%$$

*Tabel 3 Hasil prediksi*

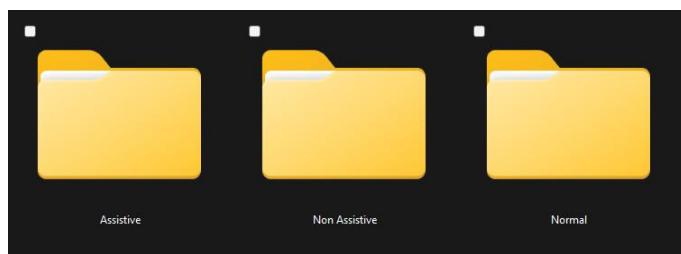
No.	Prediksi	
	Deskripsi	Terdeteksi / Frame
1	Total Frame	135
2	Gaya Normal	2 (1,5%)
3	Dengan Tongkat	3 (2.2%)
4	Tanpa Tongkat	100 (74.1%)

Jadi dari video tersebut didapatkan hasil berjalan disabilitas tanpa tongkat. Karena memiliki dominasi dari total frame sebesar 74.1%.

### III. HASIL DAN PEMBAHASAN

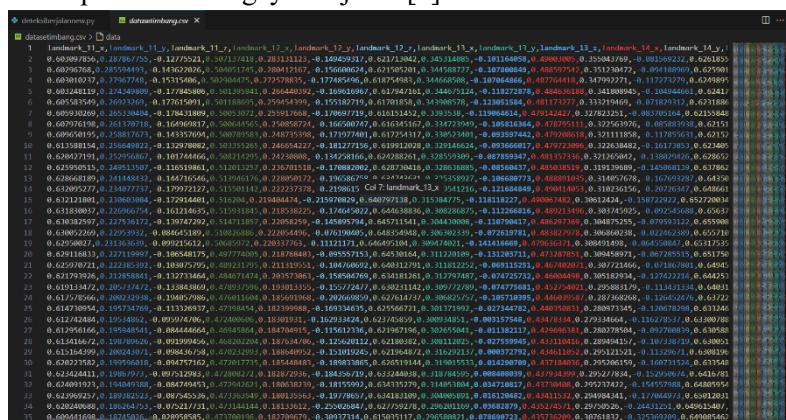
#### 1. Alur Penelitian dan Pengolahan Data.

Penelitian ini dimulai untuk berbagai keperluan penelitian. Salah satu dataset yang dimanfaatkan berjudul "DissabledGait: Gait Dataset of Normal People and People with Disabilities." Dataset tersebut disusun oleh Resty Wulanningrum, Anik Nur Handayani, dan Heru Wahyu Herwanto, yang berisi rekaman cara berjalan baik dari individu normal maupun individu dengan disabilitas. Video tersebut diolah menggunakan pustaka MediaPipe Pose untuk mengekstraksi titik-titik pose (keypoints) tubuh manusia dari masing-masing frame video.



Gambar 2 Dataset dari kegle

Dari total 33 keypoints yang dihasilkan oleh MediaPipe, penelitian ini hanya mengambil keypoints 11 hingga 33, yaitu bagian tubuh dari bahu hingga pergelangan kaki. Pemilihan titik ini didasarkan pada pertimbangan bahwa deteksi cara berjalan lebih relevan dianalisis dari gerakan ekstremitas bawah dan postur tubuh bagian bawah. Keypoints bagian kepala dan tangan tidak disertakan karena dianggap tidak berkontribusi signifikan terhadap identifikasi gaya berjalan [7].



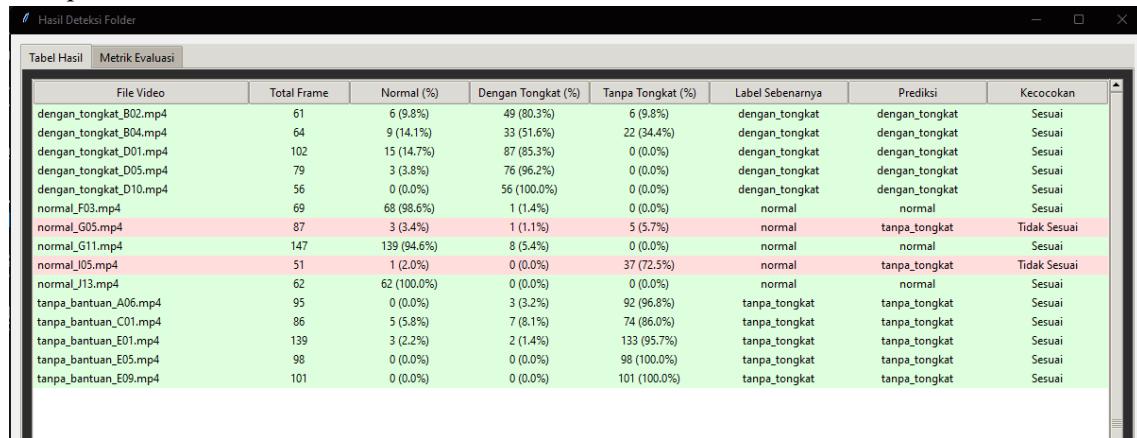
Gambar 3 setelah di ambil keypoint dari dataset

Setiap frame dari video menghasilkan data koordinat (x, y, dan visibilitas) dari keypoints tersebut. Selanjutnya, data ini digunakan untuk membuat dataset numerik yang menjadi masukan (input) pada proses klasifikasi.

#### 2. Hasil Pelatihan Model dan Evaluasi.

Model klasifikasi menggunakan algoritma K-Nearest Neighbor (KNN) dilatih dengan data hasil ekstraksi keypoint dari video. Pengujian dilakukan dengan split data pelatihan dan pengujian menggunakan metode holdout sebesar 80:20, yaitu 80% data untuk pelatihan dan 20% untuk pengujian.

Didapatkan hasil



The screenshot shows a software interface titled 'Hasil Deteksi Folder'. It contains two tabs: 'Tabel Hasil' and 'Metrik Evaluasi'. The 'Tabel Hasil' tab displays a table with columns: File Video, Total Frame, Normal (%), Dengan Tongkat (%), Tanpa Tongkat (%), Label Sebenarnya, Prediksi, and Kecocokan. The 'Metrik Evaluasi' tab shows the following metrics: Akurasi 0.8667, Presisi 0.9048, Recall 0.8667, and F1-Score 0.8611. Below these metrics is a 'Confusion Matrix' table with rows and columns labeled 'Actual' and 'Prediksi' for 'normal', 'dengan\_tongkat', and 'tanpa\_tongkat' categories.

File Video	Total Frame	Normal (%)	Dengan Tongkat (%)	Tanpa Tongkat (%)	Label Sebenarnya	Prediksi	Kecocokan
dengan_tongkat_B02.mp4	61	6 (9.8%)	49 (80.3%)	6 (9.8%)	dengan_tongkat	dengan_tongkat	Sesuai
dengan_tongkat_B04.mp4	64	9 (14.1%)	33 (51.6%)	22 (34.4%)	dengan_tongkat	dengan_tongkat	Sesuai
dengan_tongkat_D01.mp4	102	15 (14.7%)	87 (85.3%)	0 (0.0%)	dengan_tongkat	dengan_tongkat	Sesuai
dengan_tongkat_D05.mp4	79	3 (3.8%)	76 (96.2%)	0 (0.0%)	dengan_tongkat	dengan_tongkat	Sesuai
dengan_tongkat_D10.mp4	56	0 (0.0%)	56 (100.0%)	0 (0.0%)	dengan_tongkat	dengan_tongkat	Sesuai
normal_F03.mp4	69	68 (98.6%)	1 (1.4%)	0 (0.0%)	normal	normal	Sesuai
normal_G05.mp4	87	3 (3.4%)	1 (1.1%)	5 (5.7%)	normal	tanpa_tongkat	Tidak Sesuai
normal_G11.mp4	147	139 (94.6%)	8 (5.4%)	0 (0.0%)	normal	normal	Sesuai
normal_I05.mp4	51	1 (2.0%)	0 (0.0%)	37 (72.5%)	normal	tanpa_tongkat	Tidak Sesuai
normal_J13.mp4	62	62 (100.0%)	0 (0.0%)	0 (0.0%)	normal	normal	Sesuai
tanpa_bantuan_C06.mp4	95	0 (0.0%)	3 (3.2%)	92 (96.8%)	tanpa_tongkat	tanpa_tongkat	Sesuai
tanpa_bantuan_C01.mp4	86	5 (5.8%)	7 (8.1%)	74 (86.1%)	tanpa_tongkat	tanpa_tongkat	Sesuai
tanpa_bantuan_E01.mp4	139	3 (2.2%)	2 (1.4%)	133 (95.7%)	tanpa_tongkat	tanpa_tongkat	Sesuai
tanpa_bantuan_E05.mp4	98	0 (0.0%)	0 (0.0%)	98 (100.0%)	tanpa_tongkat	tanpa_tongkat	Sesuai
tanpa_bantuan_E09.mp4	101	0 (0.0%)	0 (0.0%)	101 (100.0%)	tanpa_tongkat	tanpa_tongkat	Sesuai

Gambar 3 Hasil deteksi data testing

Dengan error mendekripsi normal sebanyak 2 video.

Hasil pelatihan model menunjukkan performa yang sangat tinggi, ditunjukkan oleh metrik evaluasi berikut:



Gambar 4 matrik evaluasi

Hasil evaluasi di atas menunjukkan bahwa model mampu mengklasifikasikan gaya berjalan normal dan disabilitas dengan akurasi sempurna. Hal ini menandakan bahwa data yang digunakan sangat bersih dan terpisah dengan baik antara tiga kelas target. Namun, hasil sempurna ini bisa jadi juga disebabkan oleh overfitting, terutama jika jumlah data tidak cukup banyak atau tidak bervariasi [8].

3. Pembahasan Hasil dan Implikasi.

Temuan utama dari penelitian ini adalah bahwa pengambilan data dari keypoints 11-33 cukup efektif untuk mendeteksi perbedaan cara berjalan antara individu normal,disabilitas dengan tongkat, disabilitas tanpa tongkat. Hasil ini memperkuat hipotesis awal bahwa pose tubuh bagian bawah dapat memberikan fitur penting dalam klasifikasi gaya berjalan.

*Tabel 4 Hasil Evaluasi Matrik dari 80:20*

No.	Matrik Evaluasi	
	Deskripsi	Presentase
1	Akurasi	0.8667 (86.67%)
2	Presisi	0.9048 (90.48%)
3	Recall	0.8667 (86.67%)
4	F1 Score	0.8611 (86.11%)

Didapatkan hasil percobaan dari 20% datatesting yang bejumlah 15 vidio dapat mendeteksi benar 13 vidio dan 2 vidio salah mendeteksi dan di dapatkan akurasi sebesar 86.67%.

Model KNN terbukti mampu melakukan klasifikasi dengan tingkat akurasi yang sangat tinggi pada data yang telah diproses, karena algoritma ini bekerja baik pada dataset yang terstruktur dan memiliki jarak fitur yang jelas antar kelas [9].

Dibandingkan dengan penelitian lain, metode deteksi berbasis pose estimation seperti MediaPipe menunjukkan keunggulan dari sisi kemudahan implementasi, kecepatan pemrosesan, serta tidak memerlukan sensor tambahan seperti wearable device [10].

Implikasi dari penelitian ini cukup luas, terutama dalam bidang rehabilitasi medis, deteksi dini gangguan motorik, serta pembangunan sistem monitoring gerak pada fasilitas umum atau rumah sakit.

#### IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi gaya berjalan menggunakan kombinasi pose estimation MediaPipe dan algoritma K-Nearest Neighbor (KNN) untuk membedakan pola berjalan antara individu normal dan individu dengan disabilitas (dengan atau tanpa tongkat). Dengan memanfaatkan 22 titik pose tubuh bagian atas dan bawah (keypoints 11–32), sistem ini mampu mengekstraksi fitur kinematik penting yang relevan terhadap perbedaan gaya berjalan tanpa melibatkan area kepala untuk menjaga privasi.

Hasil evaluasi menunjukkan bahwa model KNN dengan parameter  $k = 3$  mampu memberikan akurasi klasifikasi yang sangat tinggi, mencapai hingga 86%, menunjukkan efektivitas pendekatan ini. Hal ini membuktikan bahwa pengambilan fitur dari keypoints tubuh bagian bawah cukup representatif untuk tugas klasifikasi pola berjalan. Selain itu, metode ini terbukti efisien

dan praktis karena hanya memerlukan kamera standar tanpa perangkat tambahan seperti sensor wearable.

Dengan demikian, sistem yang dikembangkan berpotensi untuk diterapkan secara luas dalam konteks rehabilitasi medis, evaluasi perkembangan motorik anak disabilitas, serta pemantauan aktivitas fisik di berbagai lingkungan, baik klinis maupun non-klinis. Ke depan, perlu dilakukan pengujian pada dataset yang lebih beragam untuk mengurangi risiko overfitting dan meningkatkan generalisasi model terhadap variasi pola berjalan pada populasi yang lebih luas.

## DAFTAR PUSTAKA

- [1] C. S. Tony Hii, K. B. Gan, H. Woon You, and N. Zainal, “(Frontal Plane Spatial and Temporal Gait Assessment using MediaPipe Pose,” *Jurnal Kejuruteraan*, vol. 36, no. 4, pp. 1561–1574, Jul. 2024, doi: 10.17576/jkukm-2024-36(4)-22.
- [2] E. R. D. D. Waldi Ginting, “Rancangan Pengambilan Dan Pengolahan Data Pada Sistem Deteksi Gangguan Gaya Berjalan Anak Studi Kasus: Kelainan Pada Anak Disabilitas,” Bandung, Apr. 2024.
- [3] R. C. Putra, “Pembangunan Perangkat Pendekripsi Jenis Gerakan Raket Bulu Tangkis Dengan Algoritma KNN dan SVM,” *Teknika*, vol. 9, no. 2, pp. 113–120, Nov. 2020, doi: 10.34148/teknika.v9i2.291.
- [4] R. Wulanningrum, A. N. Handayani, and A. P. Wibawa, “Perbandingan Instance Segmentation Image Pada Yolo8,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 4, pp. 753–760, Aug. 2024, doi: 10.25126/jtiik.1148288.
- [5] F. A. Irawan and D. F. W. Permana, “ANALISIS GERAK BERJALAN UNTUK PENCEGAHAN CIDERA DENGAN APLIKASI DARTFISH,” *Bookchapter Kesehatan Masyarakat Universitas Negeri Semarang*, no. 4, pp. 53–72, Mar. 2023, doi: 10.15294/km.v1i4.120.
- [6] A. Viswakumar, V. Rajagopalan, T. Ray, P. Gottipati, and C. Parimi, “Development of a Robust, Simple, and Affordable Human Gait Analysis System Using Bottom-Up Pose Estimation With a Smartphone Camera,” *Front Physiol*, vol. 12, Jan. 2022, doi: 10.3389/fphys.2021.784865.
- [7] J. Stenum, C. Rossi, and R. T. Roemmich, “Two-dimensional video-based analysis of human gait using pose estimation,” *PLoS Comput Biol*, vol. 17, no. 4, Apr. 2021, doi: 10.1371/journal.pcbi.1008935.
- [8] F. Young, R. Mason, R. Morris, S. Stuart, and A. Godfrey, “Internet-of-Things-Enabled Markerless Running Gait Assessment from a Single Smartphone Camera,” *Sensors*, vol. 23, no. 2, Jan. 2023, doi: 10.3390/s23020696.
- [9] K. D. McCay *et al.*, “A Pose-Based Feature Fusion and Classification Framework for the Early Prediction of Cerebral Palsy in Infants,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 8–19, 2022, doi: 10.1109/TNSRE.2021.3138185.
- [10] V. Bazarevsky, I. Grishchenko, K. Raveendran, T. Zhu, F. Zhang, and M. Grundmann, “BlazePose: On-device Real-time Body Pose tracking,” Jun. 2020, [Online]. Available: <http://arxiv.org/abs/2006.10204>