

# PENGEMBANGAN PENGENALAN AKTIVITAS MANUSIA UNTUK LANSIA BERDASARKAN NILAI AKSELEROMETER DAN FITUR STATISTIK

Azzahra Nadya Kahpiasa<sup>1</sup>, Istiqomah<sup>2</sup>, Husneni Mukhtar<sup>3</sup>,  
<sup>1, 2, 3</sup>Fakultas Teknik Elektro, Universitas Telkom, Bandung

<sup>1</sup>kahpiasakanya@student.telkomuniversity.ac.id, <sup>2</sup>istiqomah@telkomuniversity.ac.id,  
<sup>3</sup>husnenimukhtar@telkomuniversity.ac.id

Diterima pada 2 September 2023; disetujui pada 2 Oktober 2023; dan diterbitkan pada 17 Oktober 2023.

## Abstrak

Orang yang berusia di atas 60 tahun dianggap sudah lanjut usia. Penurunan fungsi fisiologis terkait usia, termasuk fungsi tulang dan otot, berkontribusi terhadap peningkatan risiko jatuh pada lansia. Salah satu keadaan yang bisa berakibat fatal adalah terjatuh. Penurunan berbagai fungsi organ yang terlibat dalam menjaga keseimbangan tubuh dapat dipengaruhi oleh dampak ini, yang mungkin berdampak pada kematian jika tidak langsung diberi penanganan medis. Penelitian sebelumnya telah melakukan uji coba dalam Pengenalan Aktivitas Manusia menggunakan model *Random Forest* dari nilai Akselerasi dan *Gyroscope*. Dalam studi ini, kami melakukan pemilihan fitur ekstraksi meliputi variabel *maximum*, *minimum*, *mean*, *Median*, *Median*, *kurtosis*, *skewness*, dan *variance* yang dikumpulkan dari data Akselerasi menggunakan sensor IMU LSM9DS1. Data Akselerasi tersebut mencakup Akselerasi X, Akselerasi Y, Akselerasi Z, dan Akselerasi *Magnitude*. Akan digunakan *Cross-validation* untuk mengetahui performansi model *Decision Tree*. Diperoleh hasil akurasi model *Decision Tree* sebesar 99,8% dan ekstraksi ciri terbaik pada *Variance* Akselerasi *Magnitude*, *Maximum* Akselerasi X, *Maximum* Akselerasi *Magnitude*, *Median* Akselerasi Z, dan *Variance* Akselerasi Z

**Kata Kunci:** Lansia, Jatuh, Kecenderungan Jatuh, *Decision Tree*, Fitur Statistik

## Abstract

Elderly people are those who are 60 years of age or older. Elderly people are more likely to fall due to age-related reductions in physiological processes, particularly bone and muscular functions. Falling is one of the symptoms that can be lethal. These effects may cause mortality if prompt medical assistance is not received due to the deterioration in numerous organ functions required to maintain body homeostasis. Previous studies have tested the *Random Forest* model from acceleration and *gyroscope* measurements to identify human activity. In this research, feature extraction was carried out utilizing variables such as *maximum*, *minimum*, *mean*, *median*, *kurtosis*, *skewness*, and *variance* that were obtained from the Acceleration data from accelerometer sensor in type IMU LSM9DS1. The Acceleration data include Acceleration X, Acceleration Y, Acceleration Z and Acceleration *Magnitude*. To evaluate the effectiveness of the *Decision Tree* model, *cross-validation* will be employed. The best feature extraction values were *Magnitude* Acceleration *Variance*, X Acceleration *Maximum*, *Magnitude* Acceleration *Maximum*, Z Acceleration *Median*, and Z Acceleration *Variance*, with a *Decision Tree* model accuracy rate of 99.8%.

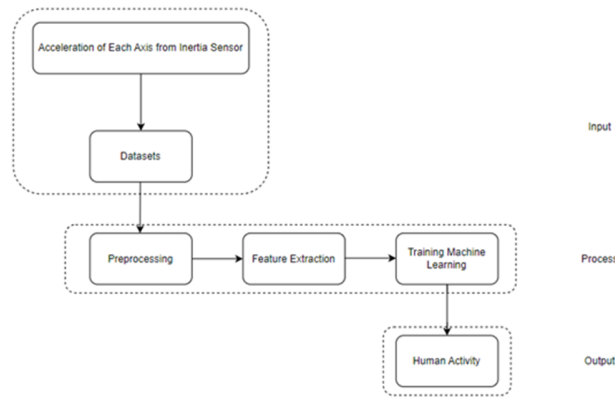
**Key Words:** Elderly, Fall, Tendency to Fall, *Decision Tree*, Statistical Feature

## 1. Pendahuluan

Lansia merupakan tahap akhir dari siklus hidup manusia. Berdasarkan UU No. 13 tahun 1998, seseorang yang berusia lebih dari 60 tahun digolongkan sebagai lansia. Lansia dapat dibagi menjadi dua kelompok menurut mata pencaharian: lansia potensial, yaitu orang lanjut usia yang masih dapat bekerja atau berpartisipasi dalam produksi barang atau jasa, dan orang lanjut usia yang lemah yang tidak dapat lagi memenuhi kebutuhan

sehari-hari dan mereka bergantung pada orang lain untuk kebutuhan mereka.

Menurut sebuah studi UNICEF, Indonesia memiliki jumlah lansia yang tumbuh paling cepat di dunia antara tahun 1990 dan 2025 [1]. Sebagai hasil dari keberhasilan pembangunan negara, harapan hidup juga meningkat. Namun saat ini, lansia semakin kurang mendapat perhatian dari masyarakat, terutama dalam hal kecukupan gizi yang mereka butuhkan. Selain itu, menurut Badan Pusat Statistik (BPS), akan ada 29,3 juta



Gambar 1. Alur *Preprocessing*

lansia di Indonesia pada tahun 2021. Jumlah tersebut setara dengan 10,82 persen dari total penduduk Indonesia (BPS, 2022). Jumlah ini diprediksi mencapai 33,69 juta pada tahun 2025, meningkat menjadi 40,95 juta di tahun 2030 dan 48,19 juta pada 2035 (Segita dkk, 2021). Peningkatan jumlah lansia memiliki konsekuensi yang kompleks. Jatuh adalah masalah umum pada tahap ini (Mahendra, 2016). Penelitian ini ditujukan agar dapat melakukan pencegahan dini pada lansia jika terjadi insiden jatuh dan kecenderungan jatuh karena hal tersebut sangat berbahaya dan jika tidak segera dilakukan pertolongan dapat berakibat fatal hingga menyebabkan kematian.

Saat ini sudah banyak dilakukan penelitian mengenai *Human Activity Recognition*, baik pada percobaan untuk variasi model *machine learning*, fitur yang digunakan, tipe *dataset* yang digunakan hingga pada aplikasi penggunaan mikrokontroler yang digunakan [2]. Salah satu contoh penelitian sebelumnya adalah pendeteksian aktivitas manusia pada lansia dengan menggunakan sensor inersia dan fitur statistik [3]. Nilai yang digunakan merupakan pembacaan nilai akselerasi dan *gyroscope* dari sensor IMU (*Inertial Measurement Unit*), kemudian menggunakan metode *XGBoost* akan dipilih urutan model *machine learning* dan lima fitur ekstraksi terbaik untuk dilakukan pelatihan.

Tujuan akhir dari riset ini, yakni untuk membangun suatu alat yang dapat melakukan klasifikasi gerak lansia pada mikrokontroler Arduino Nano 33 BLE berdasarkan nilai akselerasi yang diperoleh dari sensor IMU LSM9DS1 untuk lima kelas kategori gerakan, meliputi jatuh, kecenderungan jatuh, duduk, berdiri, dan jalan. Akan digunakan sebanyak 61.925 data akselerasi dalam proses pelatihan dengan perbandingan 80% data *training* dan 20% data *testing*.

Dilakukan pemilihan fitur terbaik untuk dilakukan *training* sesungguhnya untuk melihat performansi model *Decision Tree* yang dibangun. Pemilihan fitur ekstraksi disesuaikan dengan keterbatasan memori komputasi [4]



Gambar 2. Posisi Penempatan Arduino Nano 33 BLE



Gambar 3. Gerakan Jatuh

dari mikrokontroler Arduino Nano 33 BLE yang digunakan. Selain itu, penggunaan model *Decision Tree* disesuaikan dengan *library Micromlgen* yang akan menjadi ekstensi hasil *training* model untuk diaplikasikan di Arduino Nano 33 BLE. Hasil percobaan fitur ekstraksi dengan model *Decision Tree* disajikan dalam tabel pengujian dan *confusion matrix*.

## 2. Kajian Teori

### 2.1 Dataset

Dalam pengambilan *dataset*, digunakan sensor IMU LSM9DS1 yang ada pada Arduino Nano BLE 33 dan ditempatkan di bagian dada untuk mengukur nilai percepatan di masing-masing sumbu X, Y dan Z setiap 0,01 detik setelah *push button* ditekan. *Dataset* ini diperoleh dari 15 sampel subjek yang melakukan setiap gerakan. Terdapat 5 kelas gerakan yang diidentifikasi, yaitu berjalan, duduk (perubahan gerakan dari berdiri menjadi duduk), berdiri (perubahan gerakan dari duduk menjadi berdiri), kecenderungan jatuh, dan jatuh. Setiap subjek melakukan masing-masing aktivitas gerakan sebanyak 15 kali.

Metode yang digunakan dalam pengambilan *dataset* adalah dengan menghubungkan mikrokontroler yang telah terintegrasi sensor IMU LSM9DS1 dengan *push button* yang dikenakan oleh peserta. Ketika peserta menekan tombol, itu menunjukkan bahwa data percepatan diambil. Posisi alat terdapat pada Gambar 2.

Untuk skema gerakan yang digunakan sebagai berikut:

- **Aktivitas Jatuh:** *Dataset* gerakan jatuh hanya mencakup gerakan saat jatuh ke depan. Posisi Jatuh dapat lurus ke depan, sedikit serong kanan, dan serong kiri. Pengujian aktivitas Jatuh dilakukan sebanyak 15 kali. Skenario gerakan,



Gambar 4. Gerakan Kecenderungan Jatuh



Gambar 5. Gerakan Duduk (Standing to Sitting)

yakni posisi seseorang dari kondisi berdiri kemudian jatuh ke depan, akan dihitung berapa kali alat dapat mendeteksi gerakan jatuh pada masing-masing partisipan sesuai dengan Gambar 3.

- **Aktivitas Kecenderungan Jatuh:** *Dataset* aktivitas gerakan Kecenderungan Jatuh meliputi gerakan saat seseorang dalam kondisi “Akan” Jatuh saat dalam posisi ketika berjalan ke depan sebagaimana ilustrasi gerakan pada Gambar 4. Pengujian gerakan Kecenderungan Jatuh akan dilakukan selama 10 detik dengan posisi partisipan ketika sedang berjalan namun kondisi cenderung akan jatuh.
- **Aktivitas Duduk:** *Dataset* gerakan duduk meliputi perubahan gerakan dari posisi Berdiri menuju posisi Duduk (Standing to Sitting). Pengujian gerakan Duduk akan dilakukan duduk sebanyak 15 kali. Skenario gerakan pada Gambar 5
- **Aktivitas Berdiri:** *Dataset* gerakan berdiri meliputi perubahan gerakan dari posisi Duduk menuju posisi Berdiri (Sitting to Standing). Pengujian gerakan Berdiri akan dilakukan Duduk sebanyak 15 kali. Skenario gerakan disajikan pada Gambar 6.
- **Aktivitas Jalan:** *Dataset* gerakan Jalan akan dilakukan dengan skenario satu kali pengambilan gerakan meliputi lima langkah ke depan dengan ilustrasi gerakan pada Gambar 7. Langkah tersebut



Gambar 6. Gerakan Berdiri (Standing to Sitting)



Gambar 7. Gerakan Jalan

akan di sesuaikan dengan timer selama 15 detik. Pengujian gerakan Jalan dilakukan dengan cara partisipan melakukan gerakan jalan seperti biasa.

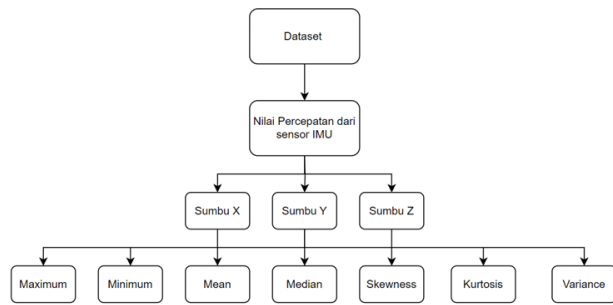
## 2.2 Preprocessing dan Ekstraksi Fitur

Setelah pengambilan *dataset*, terdapat 61.295 data akselerasi sumbu X, Y dan Z yang akan melalui proses *preprocessing*. Tujuan dilakukannya *preprocessing*, yakni untuk memastikan data yang digunakan adalah data yang berkualitas dan siap digunakan sebelum dilakukan pemodelan [5]. Setelah dilakukan *preprocessing* akan dilakukan ekstraksi fitur dengan menggunakan metode statistik. Untuk variabel statistik yang digunakan meliputi perhitungan *maximum*, *minimum*, *mean*, *median*, *skewness*, *kurtosis* dan *variance* [6].


- **Maximum** adalah nilai terbesar dalam kumpulan data, mewakili nilai tertinggi dalam *dataset*.
- **Minimum** adalah nilai terkecil dalam kumpulan data, mewakili nilai terendah dalam *dataset*.
- **Median** adalah nilai tengah dalam *dataset* ketika data disusun secara berurutan, dan merupakan ukuran sentral yang tidak dipengaruhi oleh nilai ekstrem, sehingga bermanfaat untuk data dengan distribusi condong atau adanya nilai ekstrem.

$$Median = \frac{X_{\frac{n}{2}} + X_{(\frac{n}{2} + 1)}}{2} \quad (1)$$

– n adalah jumlah data dalam kumpulan data



Gambar 8. Diagram Ekstraksi Fitur



Gambar 9. Decision Tree

- X adalah Kumpulan data yang diurutkan dari yang terkecil hingga terbesar
- $\frac{(n+1)}{2}$  adalah posisi data tengah jika jumlah data ganjil

- **Rata-rata (Mean)** adalah hasil membagi jumlah semua nilai dalam kumpulan data dengan jumlah nilai tersebut. Ini adalah ukuran sentral yang memberikan nilai khas dalam *dataset*.

$$\bar{x} = \frac{\sum x}{N} \tag{2}$$

- N jumlah data dalam sampel atau populasi
- x nilai dari data

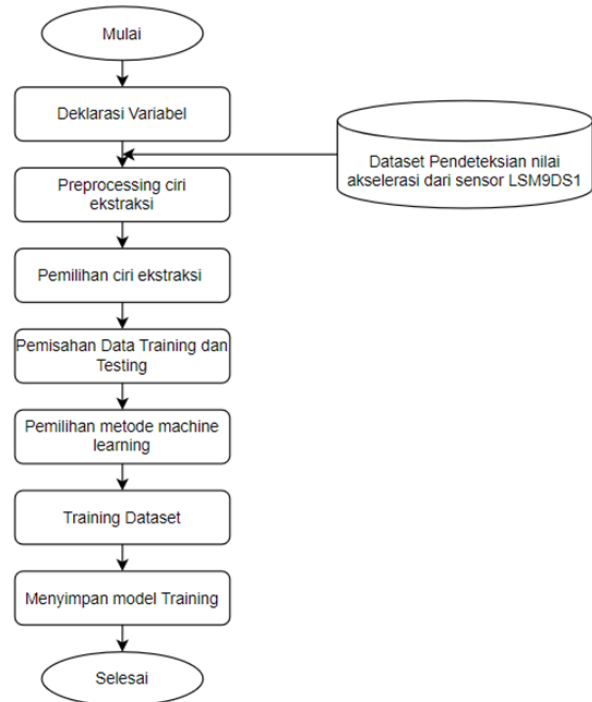
- **Skewness** mengukur ketidaksimetrisan distribusi data. *Skewness* positif menunjukkan ekor panjang di sebelah kanan distribusi, sedangkan *skewness* negatif menunjukkan ekor panjang di sebelah kiri.

$$\tilde{\mu}_3 = \frac{\sum_{i=1}^n (X_i - \bar{X})^3}{n * \sigma^3} \tag{3}$$

- **Variance** mengukur sebaran atau dispersi dalam *dataset*. *Variance* tinggi menunjukkan variasi atau sebaran yang besar dalam data.

$$S^2 = \frac{\sum (x_i - \bar{x})^2}{n - 1} \tag{4}$$

- **Kurtosis** mengukur bentuk ekor dan puncak distribusi dibandingkan dengan distribusi normal. *Kurtosis* positif menunjukkan ekor yang lebih



Gambar 10. Flowchart Machine Learning

berat dan puncak yang lebih tajam, sedangkan *kurtosis* negatif menunjukkan ekor yang lebih ringan dan puncak yang lebih datar.

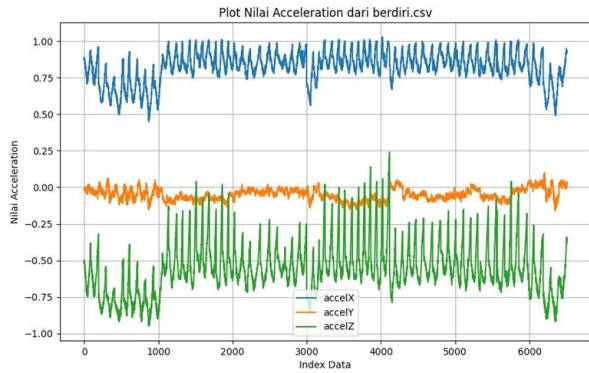
$$Kurtosis = \frac{\mu_4}{\sigma^4} \tag{5}$$

Berdasarkan Diagram Ekstraksi Fitur pada Gambar 8 akan dihasilkan 28 fitur statistik yang dihasilkan dari 7 fitur statistik untuk akselerasi sumbu X, 7 fitur statistik untuk akselerasi sumbu Y, dan 7 fitur statistik yang dihasilkan dari akselerasi sumbu Z. Akan dilakukan seleksi fitur untuk mengurangi jumlah fitur ekstraksi yang digunakan pada data pelatihan [7]. Dalam proses seleksi ini, akan dipilih 5 fitur terbaik dari model *Decision Tree* untuk dilatih pada model yang digunakan. Alasan penggunaan fitur penting adalah untuk memilih fitur yang memiliki nilai atau kinerja yang baik dalam mendukung kerja mesin.

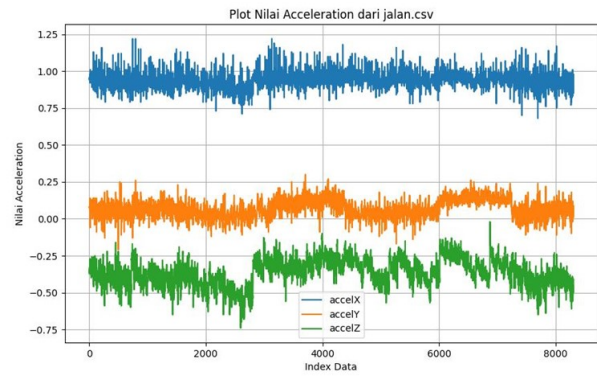
### 2.3 Classifier

Pada riset sebelumnya, model *machine learning Random Forest* telah digunakan untuk mendeteksi Pengenalan Aktivitas Manusia. Pada riset ini, kami melakukan percobaan untuk menggunakan model yang lebih tidak kompleks dibandingkan dengan *Random Forest*, yakni *Decision Tree*. Akan dilakukan juga pengujian apakah *important feature* dapat menghasilkan model yang lebih efektif dengan metode klasifikasi yang digunakan.

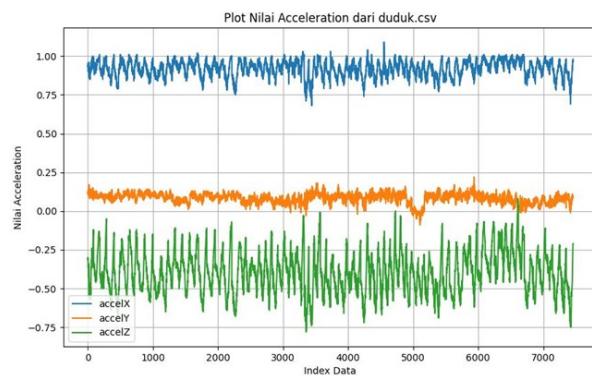
Pohon Keputusan (*Decision Tree Classifier*) adalah salah satu metode klasifikasi dalam pembelajaran mesin



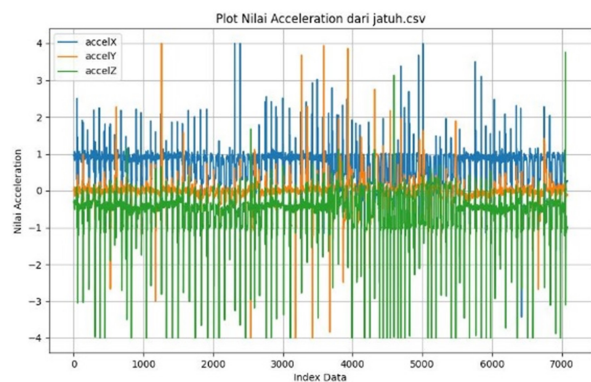
**Gambar 11. Hasil Plot Nilai Akselerasi Gerakan Berdiri**



**Gambar 13. Hasil Plot Nilai Akselerasi Gerakan Jalan**



**Gambar 12. Hasil Plot Nilai Akselerasi Gerakan Duduk**



**Gambar 14. Hasil Plot Nilai Akselerasi Gerakan Jatuh**

yang digunakan untuk memodelkan dan memecahkan masalah klasifikasi. Metode ini menghasilkan model dalam bentuk struktur pohon, di mana setiap simpul mewakili keputusan berdasarkan fitur-fitur tertentu, dan setiap cabang mewakili kemungkinan hasil atau kelas yang berbeda [27].

Pada Gambar 9 digambarkan proses pembentukan pohon dimulai dari simpul akar yang merupakan fitur paling penting untuk memisahkan data ke dalam kelompok yang berbeda. Selanjutnya, setiap cabang menggambarkan pemisahan berdasarkan fitur lain yang relevan, dan proses ini berlanjut hingga terbentuknya simpul daun yang mewakili hasil akhir atau klasifikasi [8].

Pada *Decision Tree Classifier*, terdapat beberapa rumus dan metrik yang digunakan untuk membangun dan mengukur performansi model [9]. Berikut beberapa rumus penting yang terkait dengan *Decision Tree Classifier*.

1. **Entropy (Entropi):** Entropi digunakan untuk mengukur tingkat ketidakaturan atau ketidakpastian dalam data. Persamaan entropi

sebagai berikut:

$$H(Y) = -\sum(p_i \log_2 p_i) \quad (6)$$

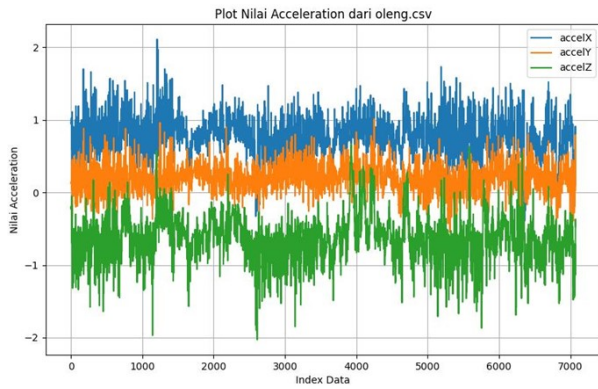
Di mana:

- $H(Y)$  adalah entropi dari variabel acak  $Y$ .
- $\sum(p_i \log_2 p_i)$  adalah jumlah dari seluruh kemungkinan nilai  $p_i$  (probabilitas) dari semua kemungkinan nilai variabel acak  $Y$ , dikalikan dengan logaritma basis 2 dari  $p_i$ .

2. **Information Gain (Gain Informasi):** *Information Gain* digunakan untuk menilai seberapa banyak informasi baru yang diperoleh dari memisahkan *dataset* berdasarkan fitur tertentu. Rumus *Information Gain* untuk kelas  $Y$  terhadap fitur  $X$  dalam *dataset* adalah:

$$Gain\ Information(Y|X) = H(Y) - H(Y|X) \quad (7)$$

di mana:



Gambar 15. Hasil Plot Nilai Akselerasi Gerakan Kecenderungan Jatuh

Tabel 1. Sepuluh Fitur Terbaik dengan Model Decision Tree

NO	Ekstraksi Fitur	Skor
1	Variance Akselerasi Magnitude	0,250
2	Maksimum Akselerasi X	0,227
3	Maksimum Akselerasi Magnitude	0,216
4	Median Akselerasi Z	0,150
5	Variance Akselerasi Z	0,034
6	Variance Akselerasi Y	0,028
7	Minimum Akselerasi Magnitude	0,021
8	Minimum Akselerasi Z	0,018
9	Median Akselerasi Y	0,015
10	Skewness Akselerasi Magnitude	0,092

- *Gain Information* ( $Y | X$ ) adalah Information Gain dari target variabel  $Y$  terhadap fitur  $X$ .
- $H(Y)$  adalah entropi dari target variabel  $Y$  sebelum pemisahan (entropi node induk).
- $H(Y|X)$  adalah entropi dari target variabel  $Y$  setelah pemisahan berdasarkan fitur  $X$  (*entropy children node*).

3. **Gini Impurity:** *Gini Impurity* adalah ukuran ketidakmurnian (impuritas) dari sebuah node dalam *Decision Tree*. Rumus *Gini Impurity* untuk node kelas  $Y$  dalam *dataset* adalah:

$$Gini(Y) = 1 - \sum p_i^2 \tag{8}$$

di mana:

- $p_i$  adalah probabilitas dari setiap kelas  $Y$  dalam *dataset*.

Tabel 2. Precision, Recall, F-1 Score 3 Fitur

Classification Report				
Activity	Precision	Recall	F1-Score	support
Fall	1,00	1,00	1,00	2277
Tendency to fall	1,00	1,00	1,00	2678
Standing to Sitting	0,97	0,98	0,97	2523
Sitting to Standing	0,98	0,96	0,97	2213
Walk	1,00	1,00	1,00	2705
Accuracy			0,99	12396
Macro avg	0,99	0,99	0,99	12396
Weighted avg	0,99	0,99	0,99	12396

Tabel 3. Precision, Recall, F-1 Score 5 Fitur

Classification Report				
Activity	Precision	Recall	F1-Score	support
Fall	1,00	1,00	1,00	2277
Tendency to fall	1,00	1,00	1,00	2678
Standing to Sitting	1,00	1,00	1,00	2523
Sitting to Standing	1,00	1,00	1,00	2213
Walk	1,00	1,00	1,00	2705
Accuracy			1,00	12396
Macro avg	1,00	1,00	1,00	12396
Weighted avg	1,00	1,00	1,00	12396

### 3. Metode

#### 3.1 Flowchart

Alur pengerjaan Machine Learning disajikan pada Gambar 10, di mana penelitian ini memanfaatkan *dataset* yang merekam nilai akselerasi sumbu X, Y dan Z yang diperoleh dari sensor inersia LSM9DS1 yang ada pada Arduino Nano BLE 33 sebagai masukan [10]. Titik pengukuran akselerasi oleh sensor inersia berada di dada pengguna, karena alat digunakan di bagian depan dada. Setelah memperoleh *dataset* akan dilakukan proses *preprocessing* untuk *handling* data agar siap dilakukan pelatihan. Dilakukan ekstrasi fitur statistika meliputi variabel *mean*, *median*, *maximum*, *minimum*, *skewness*, *kurtosis*, dan *variance*. Kemudian, dilakukan *cross validation* untuk mengetahui akurasi yang dihasilkan oleh model *Decision Tree*. Untuk mengoptimalkan kinerja model akan dilakukan pengujian untuk penggunaan 3, 5, dan 7 fitur terbaik untuk dilakukan pelatihan dengan menggunakan model *Decision Tree*. Hasil akhir dari sistem ini, dihasilkan suatu algoritma untuk mengenali lima kelas Gerakan, meliputi jatuh, kecenderungan jatuh, duduk, berdiri, dan jalan.

### 4. Hasil dan Pembahasan

#### 4.1 Preprocessing dan Pemilihan Ekstraksi Fitur

Digunakan 61.925 data akselerasi sumbu X, Y dan Z dari lima aktivitas gerakan untuk dilakukan proses *preprocessing*. Gerakan tersebut mencakup gerakan Berdiri (Gambar 11), gerakan Duduk (Gambar 12),

**Tabel 4. Precision, Recall, F-1 Score 7 Fitur**

Classification Report				
Activity	Precision	Recall	F1-Score	support
Fall	1,00	1,00	1,00	2277
Tendency to fall	1,00	1,00	1,00	2678
Standing to Sitting	1,00	1,00	1,00	2523
Sitting to Standing	1,00	1,00	1,00	2213
Walk	1,00	1,00	1,00	2705
Accuracy			1,00	12396
Macro avg	1,00	1,00	1,00	12396
Weighted avg	1,00	1,00	1,00	12396

gerakan Jalan (Gambar 13), gerakan Jatuh (Gambar 14), dan gerakan Kecenderungan Jatuh (Gambar 15). Kemudian dilakukan ekstraksi menggunakan 7 fitur statistik meliputi *mean*, *median*, *maximum*, *minimum*, *skewness*, *kurtosis*, dan *variance* terhadap Akselerasi X, Akselerasi Y, Akselerasi Z dan Akselerasi *Magnitude* sehingga akan dihasilkan 28 fitur statistik. Masing-masing fitur statistik tersebut akan memiliki nilai skor yang diperoleh dari hasil *training* data dengan model *Decision Tree* [11]. Penyeleksian fitur ditujukan agar model dapat bekerja dengan optimal untuk mengenali aktivitas gerakan.

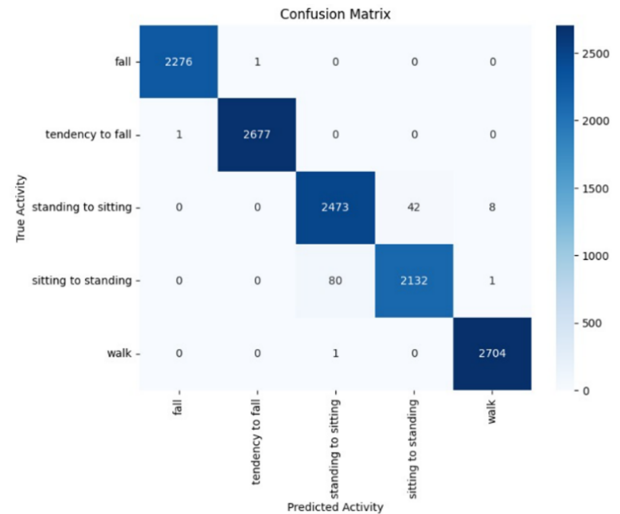
Hasil plot nilai akselerasi dari lima aktivitas kegiatan di atas menunjukkan terdapat beberapa kegiatan yang secara pola gelombang memiliki kemiripan. Kemiripan tersebut dimiliki oleh pola duduk dan pola berdiri, di mana antara gerakan duduk dan gerakan berdiri secara percepatan hanya perubahan nilai akselerasi secara vertikal. Selain itu, pola kecenderungan jatuh juga cenderung memiliki kemiripan dengan pola gerakan jatuh. Hal tersebut dikarenakan aktivitas kecenderungan jatuh melibatkan perubahan mendadak dalam akselerasi atau orientasi tubuh yang mendekati gerakan jatuh.

Tabel 1 menyajikan urutan sepuluh fitur terbaik yang dihasilkan oleh model *Decision Tree*. Selanjutnya, akan dilakukan uji coba penggunaan 3, 5, dan 7 fitur terbaik untuk menguji performansi model dalam mendeteksi klasifikasi gerakan.


**4.2 Machine Learning**

Setelah melalui tahapan *preprocessing* diperoleh pola gerakan akhir yang akan digunakan untuk pelatihan dengan model *Decision Tree*. Dari 61.925 data akselerasi sumbu X, Y, dan Z akan dilakukan pelatihan dengan model *machine learning Decision Tree* dengan perbandingan 80% data *training* dan 20% data *testing*.

Berdasarkan hasil skor ekstraksi fitur yang diperoleh dan disajikan pada Tabel 1, maka akan digunakan percobaan pelatihan model dengan menggunakan 3, 5, dan 7 fitur ekstraksi sebagai perbandingan untuk melihat akurasi dari tiap




**Gambar 16. Confusion Matrix 3 Fitur**



**Gambar 17. Confusion Matrix 5 Fitur**

penggunaan fitur ekstraksi.

1. Untuk 3 fitur digunakan fitur *Variance* Akselerasi *Magnitude*, *Maximum* Akselerasi X, *Maximum* Akselerasi *Magnitude*. Hasil performansi penggunaan 3 fitur ekstraksi disajikan dalam Confusion Matrix pada Gambar 16 dan Classification Report pada Tabel 2.
2. Penggunaan 5 Fitur Ekstraksi meliputi *Variance* Akselerasi *Magnitude*, *Maximum* Akselerasi X, *Maximum* Akselerasi *Magnitude*, *Median* Akselerasi Z, dan *Variance* Akselerasi Z. Hasil performansi model dalam penggunaan 5 fitur ekstraksi disajikan dalam Confusion Matrix pada Gambar 17 dan Classification Report pada Tabel 3.
3. Dengan 7 Fitur ekstraksi, meliputi *Variance* Akselerasi *Magnitude*, *Maximum* Akselerasi X, *Maximum* Akselerasi *Magnitude*, *Median*



Gambar 18. Confusion Matrix 7 Fitur

Kegiatan	Akurasi (%)		
	3 Fitur Ekstraksi	5 Fitur Ekstraksi	7 Fitur Ekstraksi
Jatuh	80	100	100
	60	90	90
	50	90	70
Kecenderungan Jatuh	50	80	50
	30	10	30
	40	0	40
Duduk	60	80	0
	40	60	0
	30	60	0
Berdiri	40	60	0
	40	40	0
	30	40	0
Jalan	50	90	50
	50	50	40
	30	50	40
<b>Total Akurasi</b>	<b>45,52</b>	<b>60,1</b>	<b>34,06</b>

Gambar 19. Hasil Akurasi Klasifikasi Gerakan

Akselerasi Z, dan Variance Akselerasi Z, Variance Akselerasi Y, dan Minimum Akselerasi Magnitude. Hasil performansi penggunaan 7 fitur ekstraksi disajikan dalam Confusion Matrix pada Gambar 18 dan Classification Report pada Tabel 3

### 4.3 Akurasi Klasifikasi

Sebelumnya alat sudah dilatih dalam proses machine learning untuk dapat melakukan klasifikasi data untuk pengidentifikasian gerakan. Gerakan yang diidentifikasi sesuai dengan kegiatan yang dilabeli dan dilatih pada proses machine learning, yakni gerakan jatuh, kecenderungan jatuh, duduk, berdiri, dan jalan. Data percepatan masing-masing sumbu yang diperoleh dari sensor IMU yang ada pada Arduino Nano 33 BLE akan diklasifikasikan oleh machine learning. Kemudian dilakukan pengujian untuk mengidentifikasi ketepatan hasil training model machine learning yang telah dilakukan dalam melakukan klasifikasi gerakan [12]. Dilakukan percobaan pada satu partisipan untuk model

machine learning dengan 3 fitur ekstraksi, 5 fitur ekstraksi, dan 7 fitur ekstraksi. Fitur ekstraksi yang digunakan sebagai berikut:

1. Untuk 3 fitur ekstraksi, meliputi Variance Akselerasi Magnitude, Maximum Akselerasi X, dan Maximum Akselerasi Magnitude.
2. 5 fitur ekstraksi, meliputi Variance Akselerasi Magnitude, Maximum Akselerasi X, Maximum Akselerasi Magnitude, Median Akselerasi Z, dan Variance Akselerasi Z.
3. Dengan 7 Fitur ekstraksi, meliputi Variance Akselerasi Magnitude, Maximum Akselerasi X, Maximum Akselerasi Magnitude, Median Akselerasi Z, dan Variance Akselerasi Z, Variance Akselerasi Y, dan Minimum Akselerasi Magnitude.

Berdasarkan pengujian hasil training dataset menggunakan model machine learning Decision Tree yang disajikan dalam Gambar 19, diperoleh hasil akurasi yang cukup beragam dari penggunaan 3, 5, dan 7 fitur ekstraksi. Untuk 3 Fitur ekstraksi diperoleh akurasi sebesar 45,52%. Untuk Penggunaan 5 fitur ekstraksi diperoleh akurasi sebesar 60,1% dan untuk penggunaan 7 fitur ekstraksi diperoleh akurasi sebesar 34,06%. Percobaan dilakukan masing-masing oleh 3 partisipan.

Dari percobaan dengan 3, 5 dan 7 fitur ekstraksi di atas terlihat bahwa penggunaan 5 fitur memiliki nilai akurasi yang lebih baik dibandingkan penggunaan 3 dan 7 fitur ekstraksi. Hal ini disebabkan karena ketika penggunaan fitur ekstraksi terlalu sedikit dapat mengakibatkan “Underfitting” atau bias [13] [?] sehingga model kurang mampu untuk memahami relasi antar fitur-fitur yang relevan. Sementara itu, untuk kasus 7 fitur ekstraksi dapat mengalami “Overfitting” [14] [15] atau kerumitan dimensional, di mana model menjadi terlalu sesuai dengan data pelatihan dan memiliki variansi yang tinggi, yang berakibat dapat mengurangi kemampuan model untuk melakukan generalisasi pada data baru. Selain itu, diperoleh hasil bahwa model kesulitan untuk melakukan pendeteksian gerakan Duduk dan Berdiri. Hal tersebut dikarenakan berdasarkan Gambar 11 dan Gambar 12, aktivitas duduk dan berdiri memiliki pola gerakan yang relatif mirip, terutama dalam hal variasi akselerasi sehingga model sulit untuk mengenali aktivitas tersebut. Selain itu, hal tersebut juga bisa dikarenakan kurangnya variasi dalam pengambilan dataset sehingga model memiliki variasi pola yang kurang dalam melakukan pelatihan.

### 5. Kesimpulan

Menurut hasil penelitian ini, model machine learning dapat diimplementasikan di Arduino. Klasifikasi gerakan mencakup kegiatan berjalan, jatuh, berdiri ke duduk, dan duduk ke berdiri. Dilakukan



pemilihan fitur terbaik untuk dilakukan pelatihan agar komputasi yang dilakukan lebih cepat dan model mengandung pola gerakan yang tepat. Setelah melakukan percobaan terhadap 3 fitur, 5 fitur, dan 7 fitur terbaik, diperoleh penggunaan 5 fitur ekstraksi menghasilkan akurasi yang lebih baik. Lima fitur ekstraksi tersebut meliputi *Variance* Akselerasi *Magnitude*, *Maximum* Akselerasi X, *Maximum* Akselerasi *Magnitude*, *Median* Akselerasi Z, dan *Variance* Akselerasi Z. *Mean* Akurasi yang diperoleh dari hasil *training* data tersebut, yakni 99,8%. Hasil pelatihan menunjukkan nilai *Recall*, *Precision*, dan *F1-Score* yang tinggi dengan nilai *Recall* 1,00, *Precision* 1,00, dan *F1-Score* sebesar 1,00 yang menunjukkan bahwa sistem dapat untuk mengidentifikasi lima label kegiatan meliputi gerakan jatuh, kecenderungan jatuh, duduk, berdiri dan jalan.

#### Daftar Pustaka

- [1] UNICEF, “Laporan Tahunan 2021 UNICEF Indonesia — unicef.org,” <https://www.unicef.org/indonesia/id/laporan/laporan-tahunan-2021>, 2021.
- [2] Ismail, Istiqomah, and H. Mukhtar, “Development human activity recognition for the elderly using inertial sensor and statistical feature,” in *Proceeding of the 3rd International Conference on Electronics, Biomedical Engineering, and Health Informatics*, T. Triwiyanto, A. Rizal, and W. Caesarendra, Eds. Singapore: Springer Nature Singapore, 2023, pp. 293–305.
- [3] V. S. Thomas, S. Darvesh, C. MacKnight, and K. Rockwood, “Estimating the prevalence of dementia in elderly people: A comparison of the canadian study of health and aging and national population health survey approaches,” *International Psychogeriatrics*, vol. 13, no. S1, pp. 169–175, feb 2001. [Online]. Available: <https://doi.org/10.1017%2Fs1041610202008116>
- [4] J. Liang, Z. Qin, L. Xue, X. Lin, and X. Shen, “Efficient and privacy-preserving decision tree classification for health monitoring systems,” *IEEE Internet of Things Journal*, vol. 8, no. 16, pp. 12 528–12 539, 2021.
- [5] M. M. Alam, H. Malik, M. I. Khan, T. Pardy, A. Kuusik, and Y. Le Moullec, “A survey on the roles of communication technologies in iot-based personalized healthcare applications,” *IEEE Access*, vol. 6, pp. 36 611–36 631, 2018.
- [6] N. G. Nia, E. Kaplanoglu, A. Nasab, and H. Qin, “Human activity recognition using machine learning algorithms based on imu data,” in *2023 5th International Conference on Bio-engineering for Smart Technologies (BioSMART)*, 2023, pp. 1–8.
- [7] V. V. R. A. C, R. Prasanna, P. C. Kakarla, V. S. PJ, and N. Mohan, “Implementation of tiny machine learning models on arduino 33 ble for gesture and speech recognition,” 2022.
- [8] O. Mutlu, “Processing data where it makes sense in modern computing systems: Enabling in-memory computation,” in *Proceedings of the 2019 on Great Lakes Symposium on VLSI*, ser. GLSVLSI '19. New York, NY, USA: Association for Computing Machinery, 2019, p. 5–6. [Online]. Available: <https://doi.org/10.1145/3299874.3322805>
- [9] L. Fan, Z. Wang, and H. Wang, “Human activity recognition model based on decision tree,” in *2013 International Conference on Advanced Cloud and Big Data*, 2013, pp. 64–68.
- [10] R. Kumar and R. P. Verma, “Classification algorithms for data mining: a survey.” [Online]. Available: <https://api.semanticscholar.org/CorpusID:14693893>
- [11] S. S. Nikam, “A comparative study of classification techniques in data mining algorithms,” *Orient.J. Comp. Sci. and Technol*, vol. 8, no. 1, pp. 13–19, 2015.
- [12] N. Priyanka and D. Kumar, “Decision tree classifier: a detailed survey,” *International Journal of Information and Decision Sciences*, vol. 12, no. 3, p. 246, 2020. [Online]. Available: <https://doi.org/10.1504%2Fijids.2020.108141>
- [13] G. Stein, B. Chen, A. S. Wu, and K. A. Hua, “Decision tree classifier for network intrusion detection with ga-based feature selection,” in *Proceedings of the 43rd Annual Southeast Regional Conference - Volume 2*, ser. ACM-SE 43. New York, NY, USA: Association for Computing Machinery, 2005, p. 136–141. [Online]. Available: <https://doi.org/10.1145/1167253.1167288>
- [14] I. S. Damanik, A. P. Windarto, A. Wanto, Poningsih, S. R. Andani, and W. Saputra, “Decision tree optimization in c4.5 algorithm using genetic algorithm,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, p. 012012, aug 2019. [Online]. Available: <https://dx.doi.org/10.1088/1742-6596/1255/1/012012>
- [15] Y. Liu, L. Hu, F. Yan, and B. Zhang, “Information gain with weight based decision tree for the employment forecasting of undergraduates,” in *2013 IEEE International Conference on Green Computing and Communications and IEEE Internet of Things and IEEE Cyber, Physical and Social Computing*, 2013, pp. 2210–2213.