

Terbit online pada laman web jurnal: <http://jurnal.iaii.or.id>



## **JURNAL RESTI** **(Rekayasa Sistem dan Teknologi Informasi)**

Vol. 5 No. 6 (2021) 1293– 1206

ISSN Media Elektronik: 2580-0760

# Studi Literatur Human Activity Recognition (HAR) Menggunakan Sensor Inersia

Humaira Nur Pradani<sup>1</sup>, Faizal Mahananto<sup>2</sup>

<sup>1,2</sup>Departemen Sistem Informasi, Fakultas Teknologi Elektro dan Komputer Cerdas (FT-EIC),  
Institut Teknologi Sepuluh Nopember (ITS)

<sup>1</sup>hnpradani@gmail.com, <sup>2</sup>fmahananto@gmail.com

### **Abstract**

*Human activity recognition (HAR) is one of the topics that is being widely researched because of its diverse implementation in various fields such as health, construction, and UI / UX. As MEMS (Micro Electro Mechanical Systems) evolves, HAR data acquisition can be done more easily and efficiently using inertial sensors. Inertial sensor data processing for HAR requires a series of processes and a variety of techniques. This literature study aims to summarize the various approaches that have been used in existing research in building the HAR model. Published articles are collected from ScienceDirect, IEEE Xplore, and MDPI over the past five years (2017-2021). From the 38 studies identified, information extracted are the overview of the areas of HAR implementation, data acquisition, public datasets, pre-process methods, feature extraction approaches, feature selection methods, classification models, training scenarios, model performance, and research challenges in this topic. The analysis showed that there is still room to improve the performance of the HAR model. Therefore, future research on the topic of HAR using inertial sensors can focus on extracting and selecting more optimal features, considering the robustness level of the model, increasing the complexity of classified activities, and balancing accuracy with computation time.*

**Keywords:** Human Activity Recognition, inertial sensor, accelerometer, gyroscope

### **Abstrak**

Pengenalan aktivitas manusia atau Human Activity Recognition (HAR) merupakan salah satu topik yang sedang banyak diteliti karena implementasinya yang beragam dalam berbagai bidang seperti kesehatan, konstruksi, dan UI/UX. Seiring dengan berkembangnya MEMS (Micro Electro Mechanical Systems), akuisisi data HAR dapat dilakukan dengan lebih mudah dan efisien menggunakan sensor inersia. Pengolahan data sensor inersia untuk HAR membutuhkan serangkaian proses dan beragam teknik. Studi literatur ini bertujuan untuk merangkum berbagai pendekatan yang telah digunakan pada penelitian-penelitian yang sudah ada dalam membangun model HAR. Publikasi yang ditelaah diperoleh dari ScienceDirect, IEEE Xplore, dan MDPI dalam kurun waktu lima tahun terakhir (2017-2021). Dari 38 penelitian yang berhasil diidentifikasi, serangkaian informasi yang dikumpulkan adalah gambaran mengenai bidang implementasi HAR, akuisisi data, dataset publik, metode pra-proses, pendekatan ekstraksi fitur, metode pemilihan fitur, model klasifikasi, skenario pelatihan, performa model, dan tantangan penelitian dalam topik ini. Analisis yang dilakukan menunjukkan bahwa masih terdapat ruang untuk meningkatkan performa model HAR. Oleh sebab itu, penelitian mendatang mengenai topik HAR menggunakan sensor inersia dapat difokuskan pada ekstraksi serta pemilihan fitur yang lebih optimal, mempertimbangkan tingkat *robustness* model, meningkatkan kompleksitas aktivitas yang diklasifikasi, dan menyeimbangkan antara akurasi dengan komputasi.

Kata kunci: Pengenalan aktivitas manusia, sensor inersia, akselerometer, giroskop


### **1. Pendahuluan**

Pengenalan aktivitas manusia atau dalam bahasa Inggris disebut dengan Human Acvity Recognition (HAR) merupakan salah satu topik yang sedang banyak diteliti oleh peneliti karena implementasinya yang cukup luas [1]. Tujuan utama dari HAR adalah mengenali aktivitas-aktivitas yang dilakukan manusia sehingga dapat

menghasilkan peringatan secara dini atau membantu dalam membuat keputusan tertentu. HAR digunakan dalam berbagai aspek kehidupan mulai dari pemantauan orang yang sedang sakit [2], pemantauan pekerja bangunan [3], hingga pemantauan orang dalam rumah yang menerapkan konsep *Smart Home* [4].

Saat ini, metode HAR dapat dibedakan menjadi tiga kategori berdasarkan tipe alat akuisisi data yang digunakan yakni *computer vision* [5], *standalone sensor* [6] dan *smart device* seperti *smartwatch*, *smartphone*, *smart glasses* [7]. HAR dengan *computer vision* mengandalkan sistem eksternal seperti sensor optik (kamera) yang menangkap gambar atau video untuk diolah lebih lanjut dalam mengenali aktivitas manusia. Alat yang biasa digunakan pada metode ini seperti kamera *infrared*, kamera RGB, kamera dengan sensor tangkap-gerak dan Microsoft Kinect [8]. Meskipun peneliti-peneliti telah menghasilkan model dengan akurasi yang cukup tinggi dengan metode ini, namun penerapannya masih memiliki beberapa kekurangan dan tantangan antara lain masalah privasi pengguna, memerlukan infrastruktur tambahan, dan masalah pencahayaan serta faktor lingkungan lainnya yang sangat berpengaruh terhadap akurasi model HAR [5].

Seiring berkembangnya MEMS (Micro Electro Mechanical Systems), maka muncul solusi untuk menanggulangi masalah HAR menggunakan *computer vision*, yakni dengan *standalone sensor*. Pada metode ini, data diakuisisi melalui alat yang ditempelkan pada bagian tubuh manusia. Kelebihan dari penggunaan metode ini adalah menanggulangi isu privasi, alat yang lebih ringan, lebih murah dan *portable* [9]. Sensor yang sering digunakan pada metode ini adalah akselerometer dan giroskop [10]. Kedua sensor tersebut menangkap informasi yang berbeda pada pergerakan manusia. Akselerometer menangkap informasi kecepatan pada sumbu x, y dan z (3-axis). Sedangkan giroskop digunakan untuk menangkap perubahan orientasi atau perubahan kecepatan rotasi yang disebut dengan *roll* untuk sumbu x, *pitch* untuk sumbu y, dan *yaw* untuk sumbu z [11]. Visualisasi rotasi pada masing-masing sumbu dapat dilihat pada Gambar 1.



Gambar 1. Visualisasi rotasi pada sumbu x, y, z [12]

Saat ini, sensor-sensor seperti akselerometer dan giroskop telah disematkan pada *smart devices* seperti *smartphone*, *smartwatch* maupun *smartglasses* [13]. Penggunaan *smart device* yang semakin masif memungkinkan pengambilan data untuk HAR jauh lebih

mudah dan praktis melalui perangkat tersebut. Maka dari itu, semakin banyak peneliti tertarik mengangkat topik ini [12-13].


Beberapa studi literatur mengenai HAR telah dilakukan sebelumnya. Zhang, et. al. [5] melakukan studi literatur yang berfokus pada HAR menggunakan *computer vision* yang membahas mulai dari aktivitas yang diklasifikasi, metode yang digunakan, modalitas kamera, *dataset*, performa model yang dihasilkan, dan tantangan serta arah penelitian selanjutnya. Studi literatur secara komprehensif lainnya dilakukan oleh Demrozi, et. al. [6] pada HAR menggunakan sensor inersia, fisiologis, dan lingkungan. Penelitian ini membahas mulai dari sensor yang digunakan, aktivitas yang diklasifikasi, *dataset* publik, metode pra-proses & ekstraksi fitur, model klasifikasi, dan performa model. Studi literatur serupa juga dilakukan oleh Hussain, et. al. [16] yang membahas berbagai pendekatan dalam membangun model HAR, dimana studi literatur tidak difokuskan pada jenis sensor tertentu. Di lain sisi, Ferrari, et. al. [1] melakukan studi literatur dari penelitian-penelitian HAR spesifik dalam konteks sensor pada *smartphone* saja. Namun sejauh ini, belum ada studi literatur yang berfokus pada penelitian HAR menggunakan sensor inersia dan membahas secara rinci mengenai proses rekayasa fitur data sensor 3-axis yang digunakan mulai dari pra-proses, ekstraksi fitur, dan pemilihan fitur. Maka dari itu, tujuan dari studi literatur ini adalah untuk mengetahui perkembangan metode pada penelitian terkait HAR menggunakan sensor inersia, khususnya pada proses pengolahan data sensor sebelum dilakukan pembuatan model. Kontribusi utama dari penelitian ini adalah sebagai berikut:

- Menyediakan ringkasan dari penelitian terkait HAR menggunakan sensor inersia pada 5 tahun terakhir (2017-2021)
- Mengidentifikasi metode pra-proses, rekayasa fitur, model klasifikasi, *dataset* yang digunakan, dan performa model HAR yang telah diteliti oleh peneliti sebelumnya
- Mengidentifikasi tantangan pada *domain* HAR menggunakan sensor inersia

Selanjutnya, penelitian ini dibagi menjadi tiga bagian yakni bab kedua berisikan metode studi literatur yang digunakan, bab ketiga berisikan hasil dan pembahasan, dan bab keempat berisikan kesimpulan penelitian.

## 2. Metode Penelitian

Studi literatur yang dilakukan terdiri dari beberapa tahapan. Mulai dari tahap *Identification*, *Screening*, *Eligibility*, hingga menghasilkan kumpulan artikel yang digunakan pada tahap *Included*. Tahapan pemilihan publikasi yang ditinjau tersebut mengacu pada kerangka PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses) [17] sebagaimana diringkas dalam Gambar 2.



Gambar 2. Alur Pemilihan Artikel Berdasarkan PRISMA

Pada tahap *Identification*, dilakukan pencarian publikasi artikel pada basis data jurnal secara daring. Pada tahap *Screening*, dilakukan penghilangan artikel yang duplikat dan tidak relevan dan *screening* abstrak. Selanjutnya, pada tahap *Eligibility*, dilakukan penilaian kelayakan dan kualitas artikel berdasarkan pembacaan artikel secara komprehensif. Terakhir, pada tahap *Included*, dihasilkan kumpulan artikel yang akan dilakukan telaah. Pertanyaan riset atau *research question* (RQ) juga dirumuskan agar analisis pada studi literatur lebih fokus dan terarah. Pertanyaan riset yang digunakan tertera pada Tabel 1.

Tabel 1. Pertanyaan Riset

No	Pertanyaan Riset
RQ-1	Apa saja implementasi dari pemanfaatan HAR menggunakan sensor inersia?
RQ-2	Apa saja jenis akuisisi data yang dilakukan dalam konteks HAR menggunakan sensor inersia?
RQ-3	Apa saja dataset publik yang dapat diakses untuk penelitian HAR?
RQ-4	Bagaimana metode pra-proses yang digunakan dalam memproses data sensor?
RQ-5	Bagaimana metode ekstraksi fitur yang digunakan dalam penelitian yang sudah ada?
RQ-6	Bagaimana metode pemilihan fitur yang digunakan dalam penelitian terdahulu?
RQ-7	Apa saja metode klasifikasi yang telah diterapkan dalam HAR?
RQ-8	Bagaimana skenario pelatihan dan evaluasi yang digunakan?
RQ-9	Sejauh mana performa model HAR yang telah diajukan?
RQ-10	Apa saja tantangan dalam penelitian HAR menggunakan data sensor inersia?

## 2.1. Sumber Publikasi

Artikel-artikel penelitian yang digunakan pada studi literatur ini bersumber dari tiga *database* yang dapat diakses secara daring, antara lain ScienceDirect, IEEE (Institute of Electrical and Electronics Engineers) Xplore, dan MDPI (Multidisciplinary Digital Publishing Institute). Ketiga *database* tersebut digunakan karena di dalamnya menyediakan jurnal-jurnal bereputasi dan berindeks Scopus. ScienceDirect

([www.sciencedirect.com](http://www.sciencedirect.com)) adalah *platform* utama untuk literatur *peer-review* dari Elsevier, IEEE Xplore ([www.ieeexplore.ieee.org](http://www.ieeexplore.ieee.org)) adalah perpustakaan digital yang mencakup studi di bidang komputer dan elektronik, dan MDPI ([www.mdpi.com](http://www.mdpi.com)) berisikan berbagai kumpulan artikel dari berbagai bidang.

## 2.2. Strategi Pencarian

Pencarian publikasi dilakukan pada *database* yang telah dijelaskan pada sub-bab 2.1. dengan menggunakan kata kunci sesuai konteks pengenalan aktivitas manusia yakni “Human Activity Recognition”. Lalu, kata kunci tersebut digabungkan dengan kata kunci lain untuk menspesifikkan sensor yang digunakan untuk akuisisi data. Kata kunci tambahan yang digunakan adalah “Accelerometer” OR “Gyroscope” OR “Smartphone”. Penggabungan kata kunci HAR dan sensor dilakukan dengan fungsi AND. Sebagai contoh, “Human Activity Recognition Accelerometer” merupakan salah satu kata kunci pencarian. Pencarian dilakukan pada bulan Oktober 2021. Dengan menggunakan kata kunci tersebut, ditemukan hasil pencarian sebanyak 5414 artikel.


## 2.3. Kriteria Inklusi dan Eksklusi

Kriteria inklusi dan eksklusi digunakan untuk memilih publikasi yang akan diperiksa. Kriteria ini digunakan untuk memastikan kualitas, relevansi, dan keterbaruhan publikasi. Kriteria inklusi yang digunakan antara lain (1) publikasi HAR menggunakan sensor inersia yang berfokus pada *supervised learning* atau klasifikasi, (2) publikasi dengan tipe artikel riset yang terindeks Scopus minimal Q3, (3) tahun publikasi dibatasi hanya 5 tahun terakhir yakni mulai tahun 2017, (4) publikasi berbahasa Inggris yang telah melewati proses *peer-reviewed*, (5) memiliki metodologi yang kuat dan menuliskan tahapan rekomendasi fitur serta model klasifikasi dengan jelas dan rinci. Sedangkan, kriteria eksklusi yang digunakan untuk menghapus artikel dari kumpulan artikel yang akan digunakan antara lain (1) publikasi yang tidak relevan dalam konteks HAR menggunakan sensor inersia, (2) publikasi yang duplikat, dan (3) publikasi yang bukan berbahasa Inggris.

Dengan menerapkan kriteria inklusi dan eksklusi, publikasi yang telah terpilih melewati proses penyaringan sebanyak tiga kali. Proses penyaringan pertama dilakukan berdasarkan keterhubungan judul dengan konteks yang akan dibahas. Publikasi yang dihasilkan dari tahapan ini sebanyak 121 artikel. Proses kedua adalah penyaringan berdasarkan abstrak dan ditemukan 33 artikel yang tidak sesuai konteks. Dari tahapan ini, dihasilkan 88 artikel. Proses ketiga adalah pembacaan *full-text* untuk menghilangkan artikel-artikel yang memiliki penjelasan kurang rinci dan metodologi yang kurang kuat. Sehingga, pada tahap akhir dihasilkan 38 artikel untuk dilakukan studi literatur secara sistematis.


## 2.4. Statistik Publikasi

Gambar 3 menunjukkan distribusi dari 38 publikasi yang telah tersaring melalui serangkaian proses pada Gambar 2. Dari 38 artikel, 15 artikel diantaranya adalah publikasi pada tahun 2020. Sedangkan, 23 artikel lainnya dipublikasikan pada tahun 2017, 2018, 2019 dan 2021.



Gambar 3. Distribusi Publikasi Berdasarkan Tahun

Persebaran publikasi berdasarkan indeks Scopus jurnal dapat dilihat pada Gambar 4. Sebagian besar publikasi (22 artikel - 58%) merupakan publikasi yang diterbitkan oleh jurnal bereputasi dengan indeks Scopus Q1. Sedangkan, 13 artikel lainnya adalah Q2 dan sisanya merupakan publikasi pada jurnal dengan indeks Scopus Q3. Hal ini menunjukkan bahwa jurnal yang digunakan untuk studi literatur merupakan jurnal yang berkredibilitas dan memiliki kualitas yang telah teruji.



Gambar 4. Distribusi Publikasi Berdasarkan Indeks Scopus

Jika ditinjau berdasarkan jurnal, publikasi terpilih paling banyak didapatkan dari jurnal “Sensors” yang diterbitkan oleh Multidisciplinary Digital Publishing Institute. Terdapat sejumlah 10 artikel dari jurnal tersebut. Empat artikel lainnya didapatkan dari jurnal “IEEE Access” yang diterbitkan oleh Institute of Electrical and Electronics Engineers, dan sisanya didapatkan dari jurnal lainnya.

## 3. Hasil dan Pembahasan

Artikel yang telah terpilih kemudian ditelaah lebih lanjut sesuai dengan *research question* (RQ) yang telah dirumuskan pada Tabel 1. Beberapa hal yang ditelaah yakni penerapan HAR dalam berbagai bidang, akuisisi data, dataset yang digunakan, proses pra-proses data, ekstraksi fitur, pemilihan fitur, metode klasifikasi, skenario pembelajaran dan validasi, performa model, hingga tantangan dalam topik penelitian HAR menggunakan sensor inersia.

### 3.1. RQ-1: Penerapan HAR dalam Berbagai Bidang

Penelitian mengenai pengenalan aktivitas manusia menggunakan sensor inersia memiliki banyak manfaat dan dapat diterapkan pada berbagai bidang. Beberapa bidang yang telah diidentifikasi antara lain bidang kesehatan, konstruksi bangunan, transportasi, dan UI/UX.

Dalam bidang kesehatan, pengenalan aktivitas manusia dapat dimanfaatkan untuk memonitor atau memberikan peringatan dini pada orang yang menderita penyakit tertentu atau membutuhkan penanganan khusus. Tchuente, *et. al.* [8] meneliti HAR dengan menggunakan data sensor *smartwatch* untuk membedakan aktivitas agresif dan non-agresif yang sering dijumpai pada pasien dimensia. Sedangkan Zhao, *et. al.* [18] memanfaatkan HAR untuk mengenali aktivitas terjatuh pada manusia. Hal ini sangat bermanfaat untuk memonitor aktivitas lansia yang sangat rentan terjatuh dan membutuhkan penanganan secara cepat. Selain itu, Memar, *et. al.* [2] mengeksplorasi aktivitas-aktivitas yang dilakukan penderita penyakit Parkinson pada posisi duduk untuk memudahkan *monitoring assessment* yang sebelumnya masih harus dilakukan secara subjektif dan memerlukan tenaga kesehatan khusus.

Dalam bidang konstruksi bangunan, HAR dapat digunakan untuk memantau pekerja bangunan dalam melakukan aktivitas pekerjaan. Pemantauan ini bertujuan untuk memastikan produktivitas dan keamanan pekerja. Penelitian yang oleh Sanhudo, *et. al.* [3] mengelompokkan aktivitas pekerja menjadi dua kategori, yakni aktivitas produktif dan non-produktif. Aktivitas produktif yang dimaksud adalah seperti memasang sekrup dan menggergaji. Sedangkan aktivitas non-produktif seperti duduk dan berdiri.

Dalam bidang transportasi, Gjoreski, *et. al.* [19] telah meneliti mengenai pengenalan aktivitas manusia berdasarkan moda transportasi yang digunakan menggunakan data sensor. Model HAR yang dibangun mampu mengklasifikasikan aktivitas seseorang ke dalam beberapa jenis moda transportasi seperti sepeda, mobil, bus, kereta api, dan kereta bawah tanah.

Dalam bidang UI/UX, dengan menggunakan data sensor *smartphone*, HAR dapat dilakukan untuk mengenali aktivitas-aktivitas pengguna pada *smartphone* seperti *scrolling*, melihat video, dan mengetik [20]. Hal ini bermanfaat untuk mengetahui kebiasaan atau pola pengguna sehingga dapat menghasilkan rekomendasi pengembangan UI/UX pada *smartphone*.

### 3.2. RQ-2: Akuisisi Data

Akuisisi data pada konteks HAR menggunakan sensor inersia dapat digolongkan menjadi dua jenis alat, yakni *standalone sensor* dan *smart device*. *Standalone sensor* merupakan Sensor inersia dapat di tempelkan pada tubuh manusia untuk kepentingan akuisisi data HAR. Jumlah

sensor yang ditempelkan beragam dan peletakannya disesuaikan dengan aktivitas yang akan diberi label. Contoh dari penerapan *standalone sensor* dalam konteks ini adalah penggunaan sensor akselerometer pada pergelangan tangan dan kaki untuk mengambil data pergerakan pekerja industri bangunan [3]. Sedangkan, perangkat pintar atau *smart device* mulai banyak digunakan untuk akuisisi data HAR karena penggunaannya yang meluas dan mudah. Perangkat pintar yang telah digunakan seperti *smartphone* [9], *smartwatch*, dan *smartglasses* [21]. Dari beberapa sensor yang ada pada perangkat pintar, akselerometer [9], giroskop [4] dan magnometer [14] merupakan sensor yang telah digunakan untuk pengambilan data HAR.

### 3.3. RQ-3: Dataset

Beberapa kumpulan data publik terbuka untuk komunitas HAR dan dapat diakses secara bebas di web dirangkum pada Tabel 2. Pada tabel tersebut, *dataset* dijelaskan berdasarkan jumlah label aktivitas yang diklasifikasi, jumlah subjek yang diambil datanya, jenis alat yang digunakan dalam akuisisi data, sensor yang digunakan, dan sumber *dataset*.

Tabel 2. *Dataset* Publik HAR

<i>Dataset</i>	Jumlah Aktivitas	Jumlah Subjek	<i>Device</i>	Sensor	Ref.
UCI-HAR	6	30	SP	A,G	[22]
MotionSense	6	24	SP	A,G	[23]
MHEALTH	12	10	SS	A,G,M	[24]
CogAge	7	6	SP, SW, SG	A,G,M	[25]
WISDM	6	26	SP	A	[26]
UT-Complex	13	10	SP, SS	A,G,M	[27]
SMT	12	9	SP, SS	A,G	[28]
DU-MD	10	34	SS	A	[29]
PAMAP2	18	9	SS	A,G,M	[30]
USC-HAD	12	14	SS	A	[31]
WHARF	14	16	SS	A	[32]
Sussex-Huawei	8	3	SP	A,G,M, dll.	[33]
Locomotion- Transportation (SHL)					
HAPT	12	30	SP	A,G	[34]
SPHERE	20	10	SS	A, dll.	[35]
Challenge					
UniMiB SHAR	17	30	SP	A	[36]
MobiAct	13	67	SP	A,G,M	[37]
ExtraSensory	6	60	SP	A,G	[38]
UMAFall	13	19	SP	A,G	[39]
IM-WSHA	11	10	SS	A,G	[40]

Keterangan: SS = *standalone sensor*, SP = *smartphone*, SW = *smartwatch*, A = akselerometer, G = giroskop, M = magnometer, dll. = sensor lainnya

### 3.4. RQ-4: Pra-proses Data

Sebelum data sinyal dalam bentuk deret berkala digunakan untuk pelatihan pembelajaran mesin, peneliti menerapkan serangkaian teknik untuk mempersiapkan data. Beberapa teknik yang digunakan adalah segmentasi, normalisasi, *de-noising*, dan penanganan ketidakseimbangan kelas.

#### 3.4.1. Normalisasi

Salah satu metode transformasi data yang telah dilakukan dalam konteks HAR adalah normalisasi. Normalisasi merupakan mekanisme untuk mengubah skala data menjadi rentang data yang lebih kecil. Hal ini dilakukan untuk memastikan tidak ada atribut yang sangat mendominasi dalam model karena skala yang berbeda. Namun, dari 38 publikasi yang ditelaah hanya 3 artikel yang melakukan normalisasi.

Pada penelitian oleh Meng, *et. al.* [41] metode normalisasi Z-Score digunakan untuk pra-proses data sebelum membuat model HAR pada data pasien stroke. Selain itu, penelitian yang dilakukan oleh Pires, *et. al.* [42] membandingkan empat metode normalisasi sekaligus yakni MaxAbsScaler, MinMaxScaler, RobustScaler, dan normalisasi Z-Score. Dari hasil penelitian tersebut, normalisasi tidak secara signifikan menambah akurasi model. Pada penelitian lainnya oleh San-Segundo, *et. al.* [7] diujicobakan tiga metode normalisasi yakni 0–1 Range, Mean, dan Z-score. Hasil uji coba yang didapatkan menunjukkan bahwa normalisasi fitur mampu meningkatkan akurasi pada beberapa kasus tertentu saja. Dari penelitian-penelitian tersebut dapat diketahui bahwa efektivitas penerapan metode normalisasi sangat bergantung pada metode, skenario, dan data yang digunakan.

#### 3.4.2. *De-Noising*


Secara umum, data sensor mentah cenderung memiliki *noise* yang membuat sulit untuk mencerminkan data pergerakan dalam konteks HAR secara akurat. Maka dari itu, untuk mengurangi dampak dari *noise* dalam data, teknik *filtering* perlu digunakan [15]. Metode-metode yang telah diterapkan peneliti untuk mengolah data sensor inersia antara lain Second-order band stop (notch) filter [43], Median Filter [44], Butter-Worth Filter [44], Cubical smoothing algorithm [15], Log Transform [45], Moving Mean (MM) filter [44], dan Low-Pass Filter [41].

#### 3.4.3. Penanganan Ketidakseimbangan Kelas

Data HAR yang tersedia sering kali mengalami ketidakseimbangan jumlah data karena model aktivitas yang sangat beragam dan akuisisi data yang melelahkan. Sebagai contoh, mengumpulkan data orang sehat akan lebih mudah daripada mengumpulkan data orang yang sakit karena berbagai keterbatasan. Meskipun mayoritas penelitian HAR dengan menggunakan sensor inersia tidak memperhatikan masalah ini, beberapa peneliti telah menerapkan metode tambahan untuk menanggulangi masalah ini. Penelitian oleh Meng, *et. al.* [41] menggunakan pendekatan SMOTE (Synthetic Minority Oversampling Technique) untuk menyeimbangkan data HAR pasien stroke dan orang sehat. Sedangkan, metode *down-sampling* yakni mengurangi data kelas mayoritas dilakukan pada dua penelitian lainnya [7][19].

### 3.4.4. Segmentasi

Segmentasi merupakan teknik yang digunakan untuk membagi sinyal asli menjadi beberapa segmen atau *window* yang berisikan sejumlah sampel/poin data. Jumlah sampel dalam satu *window* bergantung pada tingkat frekuensi *sampling*. Sebagai contoh, segmen sepanjang 2,5 detik pada frekuensi *sampling* 50Hz akan berisi 125 sampel [46]. Terdapat beberapa cara untuk melakukan segmentasi sinyal sensor HAR yang dapat dikategorikan ke dalam tiga kelompok, yaitu *activity-defined windows*, *event-defined windows* dan *sliding windows*. Pendekatan *sliding windows* adalah metode yang paling banyak digunakan dalam langkah segmentasi HAR [47]. Dalam pendekatan ini, sinyal sensor dibagi menjadi beberapa *window* dengan ukuran yang tetap. Jika ada tumpang tindih antara jendela yang berdekatan, teknik ini dikenal sebagai “*overlap sliding window*”, dan jika tidak, disebut dengan “*non-overlap sliding window*”. Gambar 5 menggambarkan dua jenis metode tersebut, dimana W1-W3 merepresentasikan contoh *window* yang terbentuk.



Gambar 5. Skenario segmentasi (a) *overlap* (b) *non-overlap*

Pendekatan *overlap sliding windows* diterapkan dengan beragam persentase tumpang tindih *window* yang digunakan, dimana mayoritas publikasi menggunakan persentase 50% [15][20][48][49]. Namun, terdapat beberapa angka proporsi lain yang digunakan seperti 25% [50], 33% [51], 67% [7], 75% [3], dan 96% [8]. Pendekatan *overlap* digunakan untuk mencegah kurangnya informasi aktivitas pada satu *window* sehingga mampu mengurangi kesalahan klasifikasi. Meskipun begitu, pendekatan *non-overlap sliding window* juga telah diterapkan pada beberapa penelitian [4][41] dan masih dapat menghasilkan akurasi HAR yang baik. Dari segi waktu yang diperlukan untuk membentuk satu *window*, peneliti telah menggunakan beberapa skenario waktu dari 0.3 detik hingga 256 detik.

Gambar 6 merepresentasikan grafik Treemap mengenai persebaran skenario ukuran waktu yang dibutuhkan dalam satu *window*. Dari gambar tersebut, dapat diketahui bahwa mayoritas publikasi menggunakan ukuran 2,56-5 detik untuk mendapatkan *window* dari data sensor inersia dalam mengklasifikasikan aktivitas manusia.



Gambar 6. Persebaran ukuran *window* dalam satuan waktu

### 3.5. RQ-5: Ekstraksi Fitur (*Feature Extraction*)

Ekstraksi fitur merupakan salah satu tahapan penting pada sistem HAR. Tujuan dari tahapan ini adalah untuk mendapatkan karakteristik umum dari sinyal. Fitur yang diekstraksi akan digunakan sebagai diskriminan untuk membedakan pola atau karakteristik data suatu aktivitas dan aktivitas lainnya [52]. Fitur yang diekstraksi dalam konteks HAR menggunakan data sensor inersia dapat digolongkan menjadi dua jenis ekstraksi fitur, yakni fitur buatan tangan (*hand-crafted feature*) dan fitur yang dipelajari (*learned feature*) [52]. *Hand-crafted feature* merujuk pada fitur yang didapatkan dari proses pendefinisian dan ekstraksi fitur secara manual oleh peneliti, sedangkan *learned feature* diperoleh secara otomatis saat algoritma tertentu diterapkan. *Learned feature* dapat diperoleh dengan menerapkan algoritma *deep learning* yang menggabungkan proses ekstraksi fitur dan klasifikasi secara abstrak [7]. Meskipun dengan menggunakan *learned feature* peneliti diuntungkan karena tidak perlu pendefinisian terlebih dahulu secara manual, metode ini memiliki kekurangan kompleksitasnya yang tinggi dan sulit diinterpretasi. Di sisi lain, penggunaan *hand-crafted feature* merupakan praktik yang saat ini sering digunakan oleh peneliti karena kesederhanaan perhitungan dan kompleksitas komputasi yang lebih rendah [52].

Pada *hand-crafted feature*, terdapat dua jenis ekstraksi fitur yang sering digunakan yakni disebut *time-domain* dan *frequency-domain*. Perbedaan dari keduanya adalah fitur *time-domain* diperoleh secara langsung dari sinyal yang telah diakuisisi menggunakan beberapa fungsi matematis, sedangkan fitur *frequency-domain* diperoleh dengan mentransformasi data terlebih dahulu menggunakan Fast Fourier Transform (FFT) [52]. Tabel 3 menunjukkan fitur-fitur yang sering digunakan dalam konteks HAR menggunakan sensor inersia. Meskipun kedua jenis fitur tersebut memiliki informasi yang berbeda, beberapa penelitian menggunakan hanya salah satu *domain* saja untuk mengurangi kompleksitas dan pertimbangan komputasi [14][53][54]. Di sisi lain, penggunaan kedua *domain* tersebut secara bersamaan memiliki nilai lebih karena menangkap informasi dari berbagai sudut pandang data. Terlebih, banyak peneliti juga menambahkan beberapa analisis tambahan untuk menunjang fitur-fitur tersebut, seperti fitur Cepstral [7], fitur Spectrogram-based [10], dan Wavelet Energy [15].

Tabel 3. Fitur *time-domain* dan *frequency-domain*

Kategori	Fitur	Deskripsi
<i>Time-domain</i>	Mean	Nilai rata-rata dalam satu segmen [44]
	Standar Deviation	Standar deviasi yang merepresentasikan ukuran sebaran statistik dalam satu segmen [44]
	Maximum	Nilai terbesar dalam satu segmen [44]
	Minimum	Nilai terkecil dalam satu segmen [44]
	Median Absolut	Nilai tengah absolut dalam satu segmen [55]
	IQR	Selisih antara persentil ke-75 dan persentil ke-25 dalam satu segmen [15]
	Skewness	Ukuran ketidaksimetrisan distribusi nilai dalam satu segmen [20]
	Kurtosis	Derajat keruncingan ( <i>tailedness</i> ) dalam satu segmen [20]
	Mean Absolute Deviation (MAD)	Rata-rata simpangan absolut dari titik pusat dalam satu segmen [20]
	Variance	Ukuran seberapa jauh sebuah kumpulan bilangan tersebar dalam satu segmen [20]
	Correlation	Korelasi antar variabel dalam satu segmen [9]
	Number of Peaks	Jumlah kejadian puncak dalam satu segmen [20]
	Peak to Peak	Selisih nilai maksimum dan minimum dalam satu segmen [9]
	Curve Length	Jarak antara dua titik di sepanjang bagian kurva dalam satu segmen [21]
<i>Frequency-domain</i>	Zero Crossing Rate	Jumlah kejadian fungsi menyentuh titik nol dalam satu segmen [20]
	Signal Magnitude Area (SMA)	Integral yang dinormalisasi dari 3-sumbu untuk setiap jenis sensor dalam satu segmen [20]
	Energy	Area di bawah magnitudo kuadrat dari setiap sumbu dalam satu segmen [20]
	Auto Regression Coefficient	Koefisien dari model Autoregressive (AR) dalam satu segmen [7]
	Root Mean Squared (RMS)	Rata-rata kuadrat akar dalam satu segmen [9]
	Total Sum	Total penjumlahan nilai dalam satu segmen [46]
	Spectral Entropy	Ukuran distribusi spektral dari sinyal dalam satu segmen [13]
	Median of Frequency	Nilai tengah frekuensi dalam satu segmen [45]
	Energy	Penjumlahan kuadrat magnitudo komponen FFT [19]
	Three largest magnitudes	Tiga puncak dengan besaran terbesar dari perhitungan Power Spectral Density (PSD) [19]
	Sum of Spectral Power Components	Total penjumlahan dari distribusi FFT [46]

Kategori	Fitur	Deskripsi
	Mean of Spectral Power Components	Nilai rata-rata dari distribusi FFT [46]
	Median of Spectral Power Components	Nilai tengah dari distribusi FFT [46]

### 3.6. RQ-6: Pemilihan Fitur (*Feature Selection*)

Pemilihan fitur dilakukan setelah serangkaian fitur telah diekstraksi untuk menemukan subset fitur yang optimal untuk pengolahan data pembelajaran mesin. Proses pemilihan fitur dilakukan karena terdapat konsep “Curse of Dimensionality”. Konsep ini menyatakan bahwa penambahan dimensi (fitur) akan menimbulkan masalah peningkatan eksponensial dalam volume yang dapat mempengaruhi performa dan menyebabkan komputasi yang makin tinggi [56]. Dalam konteks HAR menggunakan sensor inersia, peneliti telah menerapkan beberapa pendekatan antara lain metode *filter*, *wrapper*, *ensemble*, dan Principal Component Analysis (PCA).

#### 3.6.1. *Filter*

Metode *filter* merujuk pada metode pemilihan fitur yang dilakukan dengan menentukan peringkat fitur dimana fitur berperingkat tinggi akan dipilih dan diterapkan ke prediktor. Metode ini memiliki kelebihan dari segi komputasi yang ringan dan dapat menghindari *overfit* [57]. Beberapa pendekatan *filter* digunakan dalam konteks HAR menggunakan sensor inersia antara lain Relief F [21][58], Fisher Score [21][58], Chi-Square [21][58], Mutual Information [41], Information Gain [8], Linear Discriminant Analysis (LDA) [53], dan Korelasi Pearson [4].

#### 3.6.2. *Wrapper*

Dalam metode *wrapper*, prediktor dianggap sebagai sebuah “kotak hitam” dan kinerja prediktor sebagai fungsi tujuan untuk mengevaluasi subset variabel. Subset optimal ditemukan dengan menggunakan algoritma pencarian yang menemukan subset secara heuristik karena mengevaluasi subset  $2^N$  menjadi masalah *NP-hard* [57]. Sejumlah algoritma pencarian dapat digunakan untuk menemukan subset dari variabel yang memaksimalkan fungsi tujuan yang merupakan kinerja klasifikasi. Algoritma yang telah digunakan peneliti dalam konteks HAR antara lain Binary Grey Wolf Optimization (BGWO) [43], Random Forest Wrapper [19], dan Particle Swarm Optimization (PSO) [54].

#### 3.6.3. *Ensemble*

Pada metode *ensemble*, subset fitur diperoleh menggunakan berbagai metode dasar yang kemudian hasilnya diagregat. Sanhudo, *et. al.* [3] menggunakan beberapa algoritma seleksi fitur dasar seperti Mutual Information, F-test ANOVA (Analysis of variance), Feature Importance dan Recursive Feature Elimination

yang kemudian hasilnya digabung menggunakan algoritma *hard voting*. Sedangkan, Ahmed, *et. al.* [48] mengusulkan metode lainnya yakni pemilihan fitur dengan menggabungkan teknik *filter* dan *wrapper*. Metode ini disusun dengan dua tahapan, antara lain pemilihan fitur dengan SFFS (Sequential Forward Floating Search) yang dilakukan sebanyak lima kali sehingga menghasilkan 10 subset fitur, kemudian dilanjutkan dengan menggunakan algoritma Support Vector Machine untuk memilih subset fitur akhir yang terbaik. Selain itu, Fan, *et. al.* [9] mengusulkan metode seleksi fitur yang disebut dengan BAROQUE yang merupakan gabungan dari metode Bee Swarm Optimization (BSO) dan Deep Q Network (DQN). Pada metode ini, BSO digunakan untuk pencarian ruang fitur dan DQN digunakan untuk membuat proses pencarian lokal lebih adaptif dan lebih efisien, sehingga menghasilkan subset fitur yang optimal untuk klasifikasi HAR.

### 3.6.4. Principal Component Analysis (PCA)

Pendekatan Principal Component Analysis (PCA) digunakan oleh beberapa peneliti seperti pada penelitian [13], [14], dan [46]. Ide utama dari pendekatan ini adalah untuk mengurangi dimensi dari kumpulan data di mana terdapat sejumlah besar variabel yang saling terkait, namun juga mempertahankan sebanyak mungkin variasi yang ada dalam kumpulan data. Pengurangan ini dicapai dengan mentransformasikan ke satu set variabel baru yakni “*principal component*”, yang tidak berkorelasi dan mempertahankan sebagian besar variasi yang ada pada semua variabel aslinya [59]. Selain PCA konvensional, metode kernel PCA atau disingkat dengan kPCA juga telah digunakan oleh Hassan, *et. al.* [44]. Dalam kPCA, kernel statistik diterapkan terlebih dahulu ke fitur input, lalu diikuti oleh PCA biasa. Dengan metode ini, peneliti mampu menghasilkan 100 fitur yang paling bermakna untuk klasifikasi HAR.

## 3.7. RQ-7: Metode Klasifikasi

Secara garis besar, metode klasifikasi yang diterapkan untuk pengenalan aktivitas manusia dapat dikelompokkan menjadi tiga kategori yakni Machine Learning, Deep Learning, dan Ensemble Learning. Pada kategori Machine Learning metode-metode yang digunakan merupakan metode konvensional, sedangkan Deep Learning berisikan metode yang spesifik pengembangan dari Neural Network. Selain itu, Ensemble Learning berisikan metode gabungan dari beberapa *classifier*. Ringkasan mengenai penggunaan model klasifikasi dalam topik ini terdapat pada Tabel 4. Pada tabel tersebut terdapat tiga bagian yakni mengenai jenis pembelajaran klasifikasi yang dilakukan, algoritma yang digunakan secara spesifik, dan referensi artikel yang menggunakan algoritma tersebut dalam pengolahan data.

Tabel 4. Metode Klasifikasi

Jenis	Algoritma	Ref.
Deep Learning	Deep Believe Neural Network (DBN)	[44]
	Multi-layer Perceptron (MLP)	[7], [9], [20]
	Long-Short Term Memory (LSTM)	[10], [55], [51]
	Deep Neural Network (DNN)	[42]
	Deep Convolution Neural Networks (DCNN)	[14], [46]
	Extreme Learning Machine (ELM)	[60]
	Support Vector Machine (SVM)	[8], [13], [14], [15], [44], [43], [48], [20], [58], [21], [41], [53], [61], [62], [51]
	Decision Tree (DT)	[4], [63], [8], [43], [58], [21], [51]
	Genetic Algorithm (GA)	[43]
	Artificial Neural Network (ANN)	[4], [15], [44]
Machine Learning	Hidden Markov Model	[7], [13]
	K Nearest Neighbor (KNN)	[3], [8], [14], [20], [62], [63], [51]
	Extremely Randomized Tree	[20]
	Linear Regression	[21]
	Gaussian Process	[21]
	Threshold Selection	[21]
	Multivariate Gaussian Distribution (MGD)	[18]
	Naïve Bayes	[8], [51]
	AutoRegressive (AR)	[64]
	Maximum full a posteriori (MFAP)	[65]
Ensemble Learning	Sparse-representation-based classifier	[66]
	Voting	[50], [45], [67]
	Bagging	[20], [49], [67]
	Adaboost	[20], [49]
	Random Forest (RF)	[4], [7], [8], [13], [15], [20], [58], [50], [50]
	XGBoost	[19], [68], [67]
	Stacking	[67]
	Boosting	[3]
	Gradient Boosting	[49]
	Ensembles of nested dichotomies (END)	[49]
Others	Random Sub-space	[49]
	Rotation Forest	[54], [49]
	Average Probabilities	[45]


Selain metode klasifikasi yang telah disebutkan pada Tabel 3, terdapat metode tambahan lain untuk menunjang akurasi klasifikasi yang dihasilkan. Metode tambahan ini biasa digunakan untuk optimasi parameter pada metode tertentu. Sebagai contoh, metode *grid-search* telah digunakan untuk menyempurnakan parameter dari pohon keputusan yang dibangun untuk model Adaboost [46]. Selain itu, terdapat penerapan metode meta-heuristik lain seperti Ant Colony Optimization (ACO), Binary Grey Wolf Optimization (BGWO), dan Particle Swarm Optimization (PSO) untuk menunjang model klasifikasi HAR [43].

### 3.8. RQ-8: Skenario Pembelajaran dan Validasi

Dalam melakukan pembelajaran atau *training* pada model klasifikasi HAR, secara garis besar peneliti menerapkan dua jenis skenario [15].

#### 3.8.1. Personalisasi

Jenis pembelajaran personalisasi adalah pembelajaran HAR yang mempertimbangkan karakteristik tiap pengguna. Ide pendekatan ini muncul karena berat badan, tinggi badan, jenis kelamin dan kondisi fisik akan mempengaruhi pergerakan seseorang. Dengan kata lain, aktivitas setiap orang akan berbeda karena masing-masing individu membawa pola pribadi mereka sendiri [15]. Maka dari itu, pendekatan ini berfokus untuk membangun *classifier* yang dilatih hanya dari data aktivitas pengguna tunggal. Dalam hal ini, *dataset* pelatihan didapatkan dari data pengguna tertentu dan dilakukan ujicoba pada pengguna yang sama, tidak mempertimbangkan pengguna yang lain. Ilustrasi mengenai pendekatan ini terdapat pada Gambar 7. Namun, kekurangan dari pendekatan ini adalah membutuhkan data yang cukup banyak untuk pelatihan dari satu orang yang sama dan model yang dibangun hanya bisa diimplementasikan untuk masing-masing pengguna [46].




Gambar 7. Model Personalisasi

### 3.8.2. Generalisasi

Jenis pembelajaran generalisasi berfokus menambahkan generalisasi pengguna lainnya pada model yang dibangun. Ide ini muncul karena secara umum untuk masalah klasifikasi multi-kelas membutuhkan data pelatihan dengan jumlah yang besar, terutama ketika dimensi vektor fitur tinggi. Namun, mengumpulkan data pelatihan untuk pengenalan aktivitas membutuhkan prosedur yang melelahkan karena melibatkan banyak aktivitas. Akibatnya, dalam beberapa kasus, data pelatihan dari satu orang tidak memadai sehingga perlu menggunakan data pelatihan pengguna lain dalam membangun model [15]. Model generalisasi juga kerap dibagi menjadi dua jenis, yakni model yang sama sekali tidak melibatkan data pengguna yang diuji pada proses pelatihan, atau melibatkan sebagian data pengguna yang diuji pada proses pelatihan. Ilustrasi mengenai pendekatan generalisasi digambarkan pada Gambar 8.

Beberapa peneliti melakukan perbandingan terkait pendekatan personalisasi dan generalisasi dalam model HAR. Ferrari, et. al. [46] membandingkan tiga skenario dengan istilah *subject-dependent*, *subject-independent*, dan *hybrid*. *Subject-dependent* merujuk pada model personalisasi, sedangkan *subject-independent* merujuk pada generalisasi tipe a, dan *hybrid* merujuk pada generalisasi tipe b (lihat Gambar 8).



Gambar 8. Model Generalisasi (a) Tidak melibatkan data pengguna yang diuji (b) Melibatkan sebagian data pengguna yang diuji

Penelitian lainnya yang dilakukan oleh Chen, et. al. [15] menggunakan istilah *one-to-one* untuk skenario personalisasi, *rest-to-one* untuk generalisasi yang tidak melibatkan data pengguna uji saat pelatihan model, dan *all-to-one* untuk generalisasi yang melibatkan sebagian data pengguna yang uji saat pelatihan model. Temuan yang dihasilkan dari kedua penelitian tersebut serupa, yakni pendekatan personalisasi maupun generalisasi yang melibatkan sebagian data pengguna memiliki hasil yang lebih baik dari pendekatan lainnya. Hal ini dikarenakan data pelatihan yang digunakan mengandung informasi karakteristik khusus pengguna yang membuat model lebih cocok untuk diterapkan. Namun, pendekatan personalisasi murni cukup menantang dalam praktik aslinya, karena sistem HAR membutuhkan model yang dapat digunakan beragam pengguna [46]. Di sisi lain, pendekatan generalisasi yang melibatkan sebagian data pengguna uji saat pelatihan model dapat menangkap karakteristik pengguna, baik secara umum maupun individu serta mampu memberikan data pelatihan yang cukup memadai untuk pembuatan model. Maka dari itu, pendekatan ini terbukti mampu menghasilkan akurasi klasifikasi aktivitas manusia yang lebih baik pada beberapa kasus [15] [46].

### 3.9. RQ-9: Performa Model

Pengukuran seberapa baik model klasifikasi multi-kelas dalam konteks HAR dapat dilakukan dengan menggunakan metrik-metrik tertentu. Metrik-metrik tersebut didasarkan pada sebuah matriks yang memetakan data prediksi dan aktual yang disebut dengan *confusion matrix* [69]. Ilustrasi *confusion matrix* untuk klasifikasi multi-kelas direpresentasikan pada Gambar 9, dimana K merupakan kelas, *i* merepresentasikan kelas spesifik tertentu, dan *n* merupakan jumlah kelas.

		Hasil Prediksi		
		K <sub>0</sub> ...K <sub>i-1</sub>	K <sub>i</sub>	K <sub>i+1</sub> ...K <sub>n</sub>
Data Aktual	K <sub>0</sub>	TN	FP	TN
	K <sub>i</sub>	FN	TP	FN
Data Aktual	K <sub>i+1</sub> ...K <sub>n</sub>	TN	FP	TN
	K <sub>n</sub>	FP	TP	FN

True Negative
True Positive

False Negative
False Positive


Gambar 9. Ilustrasi Confusion Matrix Multi-Kelas

Dari *confusion matrix* yang terbentuk, kemudian dapat dihitung serangkaian metrik. Tabel 5 menunjukkan metrik-metrik yang banyak digunakan dalam klasifikasi HAR dengan menggunakan sensor inersia.

Tabel 5. Metrik Pengukuran

Metrik	Formula
Akurasi	$\frac{TP + TN}{TP + FN + FP + TN}$
Sensitivitas/ Recall	$\frac{TP}{TP + FN}$
Spesifisitas	$\frac{TN}{TN + FP}$
Precision	$\frac{TP}{TP + FP}$
F1 Score	$\frac{2TP}{2TP + FP + FN}$
MCC	$\frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$


Perbandingan performa model dari segi rata-rata akurasi yang dihasilkan tiap jenis metode klasifikasi ditunjukkan dalam Gambar 10. Nilai tersebut didapatkan dari merata-rata nilai akurasi yang dihasilkan tiap model dengan jenis metode klasifikasi tertentu seperti yang tertera pada Tabel 4. Pada Gambar 10, sumbu x menunjukkan jenis metode klasifikasi yakni Deep Learning, Machine Learning konvensional dan Ensemble Learning. Sedangkan sumbu y merepresentasikan besar rata-rata akurasi yang dihasilkan.



Gambar 10. Perbandingan Akurasi Jenis Model Klasifikasi


Dari Gambar 10, diketahui bahwa Deep Learning memiliki nilai rata-rata akurasi paling tinggi yakni sebesar 93,03%. Sedangkan, rata-rata akurasi dari penelitian yang menggunakan metode Machine Learning konvensional dan Ensemble Learning secara berurutan adalah sebesar 91,23% dan 90,1%. Hal ini menunjukkan bahwa antar jenis metode tidak memiliki perbedaan yang signifikan, yakni hanya dengan selisih 1,8-2,86%. Meskipun Deep Learning memiliki nilai akurasi yang paling tinggi, namun metode ini memiliki beberapa kekurangan antara lain sulit menginterpretasi model, membutuhkan banyak *dataset* untuk pelatihan, dan membutuhkan komputasi yang tinggi [70]. Sehingga, banyak peneliti memanfaatkan metode

Machine Learning konvensional dan Ensemble Learning dengan berbagai arsitektur model untuk menghasilkan akurasi yang lebih baik [20][49][67]. Perbandingan model klasifikasi yang lebih spesifik antar algoritma ditunjukkan pada Gambar 11 hingga Gambar 14.




Gambar 11. Perbandingan Akurasi Deep Learning

Gambar 12 menunjukkan perbandingan akurasi antar algoritma Deep Learning yang telah digunakan pada penelitian HAR menggunakan sensor inersia. Dari 6 algoritma Deep Learning yang diidentifikasi, rata-rata akurasi tertinggi dihasilkan pada algoritma Multi-Layer Perceptron (MLP) yakni sebesar 97,75%. Kemudian diikuti oleh metode Extreme Learning Machine (ELM) dengan akurasi 97,35% dan Deep Believe Neural Network (DBN) dengan akurasi sebesar 95,85%.



Gambar 12. Perbandingan Akurasi Machine Learning

Meskipun dari segi rata-rata akurasi berdasarkan jenis klasifikasi yang digunakan (Gambar 10) Machine Learning konvensional memiliki akurasi yang lebih rendah, namun akurasi paling tinggi pada jenis klasifikasi ini lebih tinggi daripada algoritma klasifikasi Deep Learning. Dapat dilihat dari Gambar 12, bahwa dua algoritma Machine Learning dengan akurasi tertinggi yakni Maximum Full A Posteriori (MFAP) dan Sparse-representation-based Classifier yang menghasilkan rata-rata akurasi sebesar 98,76% dan 98,01, secara berturut-turut.




Gambar 13. Perbandingan Akurasi Ensemble Learning

Ditinjau dari Gambar 13, algoritma Ensemble Learning juga memiliki akurasi tertinggi yang serupa dengan algoritma Machine Learning konvensional. Akurasi tertinggi pada jenis klasifikasi ini terdapat pada angka 98,74% dengan menggunakan algoritma Ensemble of nested dichotomies (END). Kemudian diikuti oleh algoritma Random sub-space dan Rotation Forest yang memiliki rata-rata akurasi sebesar 98,57% dan 98,33%. Dari analisis tersebut, dapat diketahui bahwa meskipun secara agregat metode Deep Learning memiliki nilai akurasi yang paling tinggi, namun algoritma Machine Learning dan Ensemble Learning juga memiliki akurasi yang baik jika ditinjau dari nilai akurasi tiap algoritma yang tertinggi.

Selain metode klasifikasi yang digunakan, hal penting yang juga dapat berpengaruh pada akurasi klasifikasi HAR adalah bagaimana pra-proses pengolahan data serta rekayasa fitur dilakukan [53]. Gambar 14 menunjukkan perbandingan rata-rata akurasi pada jenis rekayasa fitur yang diperoleh dari meta analisis 38 publikasi. Analisis akurasi ini difokuskan pada model-model yang menggunakan fitur *hand-crafted* untuk membahas lebih lanjut pengaruh *domain* yang digunakan.

Pada Gambar 14, grafik berwarna hijau merepresentasikan rata-rata akurasi model tanpa proses seleksi fitur. Sedangkan, grafik berwarna biru merepresentasikan rata-rata akurasi model dengan melibatkan proses seleksi fitur. Dari gambar tersebut dapat diketahui bahwa rata-rata akurasi model dengan menggunakan kombinasi fitur *time domain* dan *frequency domain* lebih tinggi dibandingkan hanya dengan *time domain* saja. Pada penelitian yang melibatkan proses seleksi fitur, rata-rata akurasi yang dihasilkan yakni sebesar 91,83% untuk penggunaan *time domain* dan *frequency domain*. Angka ini lebih tinggi dari rata-rata akurasi *time domain* saja dengan selisih 0,91%. Sejalan dengan hal tersebut, rata-rata akurasi pada penelitian yang menggunakan kombinasi fitur *time domain* dan *frequency domain* namun tidak melakukan seleksi fitur adalah sebesar 96,02%. Angka ini lebih

tinggi 0,54% dari rata-rata akurasi penelitian yang hanya menggunakan fitur *time domain* saja. Selain itu, terlihat perbedaan yang cukup signifikan dari akurasi penelitian yang menggunakan hanya fitur pada *frequency domain* saja. Penelitian yang melakukan proses seleksi fitur dan hanya menggunakan fitur *frequency domain* saja menghasilkan akurasi tertinggi yakni sebesar 98,67%. Sedangkan tanpa seleksi fitur hanya 88,87%. Hasil ini mencerminkan bahwa proses ekstraksi fitur dan pemilihan fitur dapat berdampak pada performa model yang dihasilkan [52].



Gambar 14. Perbandingan Akurasi Ensemble Learning

### 3.10. RQ-10: Tantangan dan Penelitian Selanjutnya

Dari hasil telaah 38 artikel penelitian yang telah dilakukan, dapat diidentifikasi beberapa tantangan dalam penelitian HAR yang perlu diperhatikan pada penelitian selanjutnya. Tantangan pertama adalah terkait konsep “Curse of Dimensionality”. Salah satu permasalahan yang dihadapi pada penelitian konteks HAR menggunakan sensor inersia adalah banyaknya fitur yang diekstraksi sehingga membutuhkan komputasi yang tinggi [9][48]. Data sensor inersia memiliki dimensi yang tinggi karena masing-masing sensor menghasilkan nilai pada tiga sumbu, yakni pada sumbu x, y dan z [71]. Sehingga, proses seleksi fitur perlu menjadi sebuah hal yang menjadi pertimbangan dalam penelitian selanjutnya. Berbagai algoritma pemilihan fitur dapat digunakan seperti yang telah dijelaskan pada sub-bab 3.6.

Tantangan kedua yakni memastikan fitur-fitur yang digunakan sebagai input model HAR merupakan kumpulan fitur yang optimal. Jika fitur tidak bisa menjadi diskriminan yang baik untuk klasifikasi aktivitas, maka model yang dihasilkan cenderung memiliki akurasi yang lebih rendah c. Pengembangan terkait ekstraksi fitur yang dapat diusulkan yakni penambahan analisis baru selain ekstraksi fitur pada *time-domain* dan *frequency-domain*, seperti tambahan analisis statistik pada sinyal aktivitas dengan Detrended Fluctuation Analysis (DFA) [72].

Tantangan ketiga terkait dengan tingkat *robustness* dari model yang terbentuk. *Robustness* model merupakan representasi dari seberapa umum model dapat digunakan dalam berbagai studi kasus [7]. Dalam konteks ini,

*robustness* model dapat diukur melalui pengujian pada diperhatikan, ekstraksi fitur yang optimal untuk data yang berbeda, misalnya pada data dengan penempatan sensor yang berbeda [4] atau karakter subjek yang berbeda [46]. Model HAR yang terbentuk perlu mempertimbangkan faktor *robustness* dengan melakukan validasi model yang diusulkan melalui pengujian pada beberapa *dataset* [43][67].

Tantangan keempat adalah terkait jumlah dan kompleksitas aktivitas. Model-model HAR yang telah dikembangkan mayoritas digunakan untuk mengidentifikasi aktivitas dasar sehari-hari seperti berjalan, berdiri, duduk, dan naik turun tangga [58][55].

Padahal pada kenyataannya, aktivitas manusia sangat beragam dan kompleks [13]. Terlebih, saat ini jumlah aktivitas yang telah diklasifikasi pada penelitian HAR cukup terbatas, yakni tidak lebih dari 20 aktivitas (lihat Tabel 2). Hal ini dapat menjadi peluang untuk penelitian selanjutnya dengan menambahkan lebih banyak data aktivitas HAR dan memilih aktivitas yang lebih kompleks.

Tantangan kelima adalah mengenai *trade-off* antara akurasi dan komputasi. Dalam mengembangkan model HAR menggunakan sensor inersia, faktor *trade-off* akurasi dan komputasi perlu diperhatikan [54]. Hal ini karena pemrosesan yang dilakukan harus secara *real-time* pada alat yang terbatas, sedangkan akurasi yang dihasilkan oleh model juga tidak boleh banyak berkurang [51]. Sehingga, penelitian mengenai HAR menggunakan sensor inersia selanjutnya perlu mengukur dan menganalisis keseimbangan antara komputasi yang dibutuhkan dalam memproses data dan seberapa baik akurasi yang dihasilkan.

#### 4. Kesimpulan

Human Activity Recognition (HAR) merupakan topik penelitian yang sedang banyak diteliti karena pemanfaatannya yang sangat luas. Studi literatur ini dilakukan untuk mengetahui lebih lanjut tren penelitian pada studi kasus tersebut. Studi literatur dilakukan melalui beberapa tahapan mulai identifikasi publikasi rujukan, *screening* penelitian, pengecekan kelayakan, dan didapatkan 38 penelitian terkait HAR dengan menggunakan sensor inersia. Dari 38 penelitian tersebut, dilakukan meta analisis terkait implementasi dalam berbagai bidang, jenis akuisisi data yang dilakukan, *dataset* publik yang dapat diakses, metode pra-proses yang digunakan dalam memproses data sensor, metode ekstraksi fitur yang digunakan dalam penelitian yang sudah ada, metode pemilihan fitur, metode klasifikasi, skenario pelatihan, performa model HAR dan terakhir mengidentifikasi tantangan dalam penelitian HAR menggunakan data sensor inersia. Dari hasil studi literatur yang telah dilakukan, diketahui bahwa model-model yang dihasilkan masih belum optimal dari segi akurasi. Hal ini disebabkan oleh beberapa hal, antara lain adanya konsep “Curse of Dimensionality” yang harus

menunjang model, tingkat *robustness* model, kompleksitas aktivitas yang diklasifikasi, dan *trade-off* antara akurasi-komputasi. Maka dari itu, penelitian mendatang mengenai HAR menggunakan sensor inersia dapat dilakukan dengan mempertimbangkan berbagai aspek tersebut. Sedangkan, studi literatur ini dapat dikembangkan lebih lanjut dengan penambahan publikasi yang ditelaah dan analisis lanjutan yang lebih rinci pada tiap proses pembuatan model HAR.

#### Ucapan Terimakasih

Terima kasih ditujukan kepada semua pihak yang terlibat pada penelitian ini yakni dosen pembimbing dan Institut Teknologi Sepuluh Nopember yang telah menyediakan akses untuk data penelitian.

#### Daftar Rujukan

- [1] A. Ferrari, D. Micucci, M. Mobilio, and P. Napoletano, “Trends in human activity recognition using smartphones,” *J. Reliab. Intell. Environ.*, vol. 7, no. 3, pp. 189–213, 2021, doi: 10.1007/s40860-021-00147-0.
- [2] S. Memar, M. Delrobaei, G. Gilmore, K. McIsaac, and M. Jog, “Segmentation and detection of physical activities during a sitting task in Parkinson’s disease participants using multiple inertial sensors,” *J. Appl. Biomed.*, vol. 15, no. 4, pp. 282–290, 2017, doi: 10.1016/j.jab.2017.05.002.
- [3] L. Sanhudo *et al.*, “Activity classification using accelerometers and machine learning for complex construction worker activities,” *J. Build. Eng.*, vol. 35, no. October 2020, 2021, doi: 10.1016/j.jobe.2020.102001.
- [4] M. Ehatisham-Ul-Haq, M. A. Azam, Y. Amin, and U. Naeem, “C2FHAR: Coarse-to-Fine Human Activity Recognition with Behavioral Context Modeling Using Smart Inertial Sensors,” *IEEE Access*, vol. 8, pp. 7731–7747, 2020, doi: 10.1109/ACCESS.2020.2964237.
- [5] S. Zhang, Z. Wei, J. Nie, L. Huang, S. Wang, and Z. Li, “A Review on Human Activity Recognition Using Vision-Based Method,” *J. Healthc. Eng.*, vol. 2017, 2017, doi: 10.1155/2017/3090343.
- [6] F. Demrozi, G. Pravadelli, A. Bihorac, and P. Rashidi, “Human Activity Recognition Using Inertial, Physiological and Environmental Sensors: A Comprehensive Survey,” *IEEE Access*, vol. 8, no. D1, pp. 210816–210836, 2020, doi: 10.1109/ACCESS.2020.3037715.
- [7] R. San-Segundo, H. Blunck, J. Moreno-Pimentel, A. Stisen, and M. Gil-Martín, “Robust Human Activity Recognition using smartwatches and smartphones,” *Eng. Appl. Artif. Intell.*, vol. 72, no. March, pp. 190–202, 2018, doi: 10.1016/j.engappai.2018.04.002.
- [8] F. Tchuente, N. Baddour, and E. D. Lemaire, “Classification of aggressive movements using smartwatches,” *Sensors (Switzerland)*, vol. 20, no. 21, pp. 1–12, 2020, doi: 10.3390/s20216377.
- [9] C. Fan and F. Gao, “Enhanced human activity recognition using wearable sensors via a hybrid feature selection method,” *Sensors*, vol. 21, no. 19, 2021, doi: 10.3390/s21196434.
- [10] O. S. Eyobu and D. S. Han, “Feature representation and data augmentation for human activity classification based on wearable IMU sensor data using a deep LSTM neural network,” *Sensors (Switzerland)*, vol. 18, no. 9, pp. 1–26, 2018, doi: 10.3390/s1809216377.
- [11] I. Arun Faisal, T. Waluyo Purboyo, and A. Siswo Raharjo Ansori, “A Review of Accelerometer Sensor and Gyroscope Sensor in IMU Sensors on Motion Capture,” *J. Eng. Appl. Sci.*, vol. 15, no. 3, pp. 826–829, 2019, doi:

- 10.36478/jeasci.2020.826.829.
- [12] "Joints — Aldebaran 2.4.3.28-r2 documentation." [http://doc.aldebaran.com/2-4/family/robots/joints\\_robot.html](http://doc.aldebaran.com/2-4/family/robots/joints_robot.html) (accessed Dec. 02, 2021).
- [13] M. Fatima Amjad, Muhammad Hassan Khan, Muhammad Adeel Nisar,, Muhammad Shahid Farid Grzegorzek, "A Comparative Study of Feature Selection Approaches for Human Activity Recognition Using Multimodal Sensory Data," *Sensors*, pp. 1–21, 2021.
- [14] J. Sena, J. Barreto, C. Caetano, G. Cramer, and W. R. Schwartz, "Human activity recognition based on smartphone and wearable sensors using multiscale DCNN ensemble," *Neurocomputing*, vol. 444, pp. 226–243, 2021, doi: 10.1016/j.neucom.2020.04.151.
- [15] Y. Chen and C. Shen, "Performance Analysis of Smartphone-Sensor Behavior for Human Activity Recognition," *IEEE Access*, vol. 5, no. c, pp. 3095–3110, 2017, doi: 10.1109/ACCESS.2017.2676168.
- [16] Z. Hussain, M. Sheng, S. Member, and W. Emma Zhang, "Different Approaches for Human Activity Recognition-A Survey," 2019.
- [17] M. J. Page *et al.*, "The PRISMA 2020 statement: an updated guideline for reporting systematic reviews," *BMJ*, vol. 372, Mar. 2021, doi: 10.1136/BMJ.N71.
- [18] S. Zhao, W. Li, and J. Cao, "A user-adaptive algorithm for activity recognition based on K-means clustering, local outlier factor, and multivariate gaussian distribution," *Sensors (Switzerland)*, vol. 18, no. 6, 2018, doi: 10.3390/s18061850.
- [19] M. Gjoreski *et al.*, "Classical and deep learning methods for recognizing human activities and modes of transportation with smartphone sensors," *Inf. Fusion*, vol. 62, no. April 2019, pp. 47–62, 2020, doi: 10.1016/j.inffus.2020.04.004.
- [20] S. Zhuo, L. Sherlock, G. Dobbie, Y. S. Koh, G. Russello, and D. Lottridge, "REAL-time smartphone activity classification using inertial sensors—recognition of scrolling, typing, and watching videos while sitting or walking," *Sensors (Switzerland)*, vol. 20, no. 3, pp. 1–18, 2020, doi: 10.3390/s20030655.
- [21] S. Fan, Y. Jia, and C. Jia, "A feature selection and classification method for activity recognition based on an inertial sensing unit," *Inf.*, vol. 10, no. 10, 2019, doi: 10.3390/info10100290.
- [22] J.-L. Reyes-Ortiz, L. Oneto, A. Samá, A. Ghio, X. Parra, and D. Anguita, "Transition-Aware Human Activity Recognition Using Smartphones."
- [23] M. Malekzadeh, R. G. Clegg, A. Cavallaro, and H. Haddadi, "Mobile Sensor Data Anonymization," vol. 10, no. 19, 2019, doi: 10.1145/3302505.3310068.
- [24] O. Banos *et al.*, "mHealthDroid: A Novel Framework for Agile Development of Mobile Health Applications."
- [25] M. A. Nisar, K. Shirahama, F. Li, X. Huang, and M. Grzegorzek, "Rank Pooling Approach for Wearable Sensor-Based ADLs Recognition," *Sensors 2020*, Vol. 20, Page 3463, vol. 20, no. 12, p. 3463, Jun. 2020, doi: 10.3390/S20123463.
- [26] G. M. Weiss, K. Yoneda, and T. Hayajneh, "Smartphone and Smartwatch-Based Biometrics Using Activities of Daily Living," *IEEE Access*, vol. 7, pp. 133190–133202, 2019, doi: 10.1109/ACCESS.2019.2940729.
- [27] M. Shoaib, S. Bosch, O. D. Incel, H. Scholten, and P. J. M. Havinga, "Complex Human Activity Recognition Using Smartphone and Wrist-Worn Motion Sensors," *Sensors 2016*, Vol. 16, Page 426, vol. 16, no. 4, p. 426, Mar. 2016, doi: 10.3390/S16040426.
- [28] C. Fan and F. Gao, "A New Approach for Smoking Event Detection Using a Variational Autoencoder and Neural Decision Forest," *IEEE Access*, vol. 8, pp. 120835–120849, 2020, doi: 10.1109/ACCESS.2020.3006163.
- [29] S. S. Saha, S. Rahman, M. J. Rasna, A. K. M. Mahfuzul Islam, and M. A. Rahman Ahad, "DU-MD: An open-source human action dataset for ubiquitous wearable sensors," *2018 Jt. 7th Int. Conf. Informatics, Electron. Vis. 2nd Int. Conf. Imaging, Vis. Pattern Recognition, ICIEV-IVPR 2018*, pp. 567–572, 2019, doi: 10.1109/ICIEV.2018.8641051.
- [30] A. Reiss and D. Stricker, "Creating and benchmarking a new dataset for physical activity monitoring," *ACM Int. Conf. Proceeding Ser.*, 2012, doi: 10.1145/2413097.2413148.
- [31] M. Zhang and A. A. Sawchuk, "USC-HAD: A Daily Activity Dataset for Ubiquitous Activity Recognition Using Wearable Sensors," *Proc. 2012 ACM Conf. Ubiquitous Comput. - UbiComp '12*, 2012, doi: 10.1145/2370216.
- [32] B. Bruno, F. Mastrogiovanni, and A. Sgorbissa, "A public domain dataset for ADL recognition using wrist-placed accelerometers," *IEEE RO-MAN 2014 - 23rd IEEE Int. Symp. Robot Hum. Interact. Commun. Human-Robot Co-Existence Adapt. Interfaces Syst. Dly. Life. Ther. Assist. Soc. Engag. Interact.*, pp. 738–743, Oct. 2014, doi: 10.1109/ROMAN.2014.6926341.
- [33] H. Gjoreski *et al.*, "The University of Sussex-Huawei Locomotion and Transportation Dataset for Multimodal Analytics with Mobile Devices," *IEEE Access*, vol. 6, pp. 42592–42604, 2018, doi: 10.1109/ACCESS.2018.2858933.
- [34] D. Wang, J. Wan, J. Chen, and Q. Zhang, "An Online Dictionary Learning-Based Compressive Data Gathering Algorithm in Wireless Sensor Networks," *Sensors 2016*, Vol. 16, Page 1547, vol. 16, no. 10, p. 1547, Sep. 2016, doi: 10.3390/S16101547.
- [35] N. Twomey *et al.*, "The SPHERE Challenge: Activity Recognition with Multimodal Sensor Data," Mar. 2016, Accessed: Oct. 30, 2021. [Online]. Available: <https://arxiv.org/abs/1603.00797v3>.
- [36] D. Micucci, M. Mobilio, and P. Napoletano, "UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones," *Appl. Sci. 2017*, Vol. 7, Page 1101, vol. 7, no. 10, p. 1101, Oct. 2017, doi: 10.3390/APP7101101.
- [37] G. Vavoulas, C. Chatzaki, T. Malliotakis, M. Pediaditis, and M. Tsiknakis, "The MobiAct Dataset: Recognition of Activities of Daily Living using Smartphones," Accessed: Oct. 30, 2021. [Online]. Available: [www.bmi.teicrete.gr](http://www.bmi.teicrete.gr).
- [38] Y. Vaizman, K. Ellis, G. Lanckriet, and N. Weibel, "Extrasensory app: Data collection in-the-wild with rich user interface to self-report behavior," *Conf. Hum. Factors Comput. Syst. - Proc.*, vol. 2018-April, Apr. 2018, doi: 10.1145/3173574.3174128.
- [39] E. Casilar, J. A. Santoyo-Ramón, and J. M. Cano-García, "UMAFall: A Multisensor Dataset for the Research on Automatic Fall Detection," *Procedia Comput. Sci.*, vol. 110, pp. 32–39, 2017, doi: 10.1016/J.PROCS.2017.06.110.
- [40] S. B. ud din Tahir, A. Jalal, and K. Kim, "Wearable Inertial Sensors for Daily Activity Analysis Based on Adam Optimization and the Maximum Entropy Markov Model," *Entropy 2020*, Vol. 22, Page 579, vol. 22, no. 5, p. 579, May 2020, doi: 10.3390/E22050579.
- [41] L. Meng *et al.*, "Exploration of human activity recognition using a single sensor for stroke survivors and able-bodied people," *Sensors (Switzerland)*, vol. 21, no. 3, pp. 1–18, 2021, doi: 10.3390/s21030799.
- [42] I. M. Pires, F. Hussain, N. M. Garcia, P. Lameski, and E. Zdravevski, "Homogeneous data normalization and deep learning: A case study in human activity classification," *Futur. Internet*, vol. 12, no. 11, pp. 1–14, 2020, doi: 10.3390/fi12110194.
- [43] A. Jalal, M. Batool, and K. Kim, "Stochastic recognition of physical activity and healthcare using tri-axial inertial wearable sensors," *Appl. Sci.*, vol. 10, no. 20, pp. 1–20, 2020, doi: 10.3390/app10207122.
- [44] M. M. Hassan, M. Z. Uddin, A. Mohamed, and A. Almogren, "A robust human activity recognition system using smartphone sensors and deep learning," *Futur. Gener. Comput. Syst.*, vol. 81, pp. 307–313, 2018, doi: 10.1016/j.future.2017.11.029.
- [45] J. Saha, C. Chowdhury, I. R. Chowdhury, S. Biswas, and N. Aslam, "An ensemble of condition based classifiers for device independent detailed human activity recognition using smartphones," *Inf.*, vol. 9, no. 4, 2018, doi: 10.3390/info9040094.
- [46] A. Ferrari, D. Micucci, M. Mobilio, and P. Napoletano, "On the

- Personalization of Classification Models for Human Activity Recognition,” *IEEE Access*, vol. 8, pp. 32066–32079, 2020, doi: 10.1109/ACCESS.2020.2973425.
- [47] A. Dehghani, O. Sarbishei, T. Glatard, and E. Shihab, “A Quantitative Comparison of Overlapping and Non-Overlapping Sliding Windows for Human Activity Recognition Using Inertial Sensors,” *Sensors (Basel)*, vol. 19, no. 22, Nov. 2019, doi: 10.3390/S19225026.
- [48] N. Ahmed, J. I. Rafiq, and M. R. Islam, “Enhanced human activity recognition based on smartphone sensor data using hybrid feature selection model,” *Sensors (Switzerland)*, vol. 20, no. 1, 2020, doi: 10.3390/s20010317.
- [49] K. N. K. A. Rahim, I. Elamvazuthi, L. I. Izhar, and G. Capi, “Classification of human daily activities using ensemble methods based on smartphone inertial sensors,” *Sensors (Switzerland)*, vol. 18, no. 12, 2018, doi: 10.3390/s18124132.
- [50] R. Zhu *et al.*, “Efficient Human Activity Recognition Solving the Confusing Activities Via Deep Ensemble Learning,” *IEEE Access*, vol. 7, pp. 75490–75499, 2019, doi: 10.1109/ACCESS.2019.2922104.
- [51] W. Qi, H. Su, and A. Aliverti, “A Smartphone-Based Adaptive Recognition and Real-Time Monitoring System for Human Activities,” *IEEE Trans. Human-Machine Syst.*, vol. 50, no. 5, pp. 414–423, 2020, doi: 10.1109/THMS.2020.2984181.
- [52] M. B. Dehkordi, A. Zaraki, and R. Setchi, “Feature extraction and feature selection in smartphone-based activity recognition,” *Procedia Comput. Sci.*, vol. 176, pp. 2655–2664, 2020, doi: 10.1016/j.procs.2020.09.301.
- [53] R. A. Bhuiyan, N. Ahmed, M. Amiruzzaman, and M. R. Islam, “A robust feature extraction model for human activity characterization using 3-axis accelerometer and gyroscope data,” *Sensors (Switzerland)*, vol. 20, no. 23, pp. 1–17, 2020, doi: 10.3390/s20236990.
- [54] A. Elsts, N. Twomey, R. McConville, and I. Craddock, “Energy-efficient activity recognition framework using wearable accelerometers,” *J. Netw. Comput. Appl.*, vol. 168, no. October 2019, p. 102770, 2020, doi: 10.1016/j.jnca.2020.102770.
- [55] Z. Chen, L. Zhang, Z. Cao, and J. Guo, “Distilling the Knowledge from Handcrafted Features for Human Activity Recognition,” *IEEE Trans. Ind. Informatics*, vol. 14, no. 10, pp. 4334–4342, 2018, doi: 10.1109/TII.2018.2789925.
- [56] E. Keogh and A. Mueen, “Curse of Dimensionality,” *Encycl. Mach. Learn. Data Min.*, pp. 314–315, 2017, doi: 10.1007/978-1-4899-7687-1\_192.
- [57] G. Chandrashekhar and F. Sahin, “A survey on feature selection methods,” 2014, doi: 10.1016/j.compeleceng.2013.11.024.
- [58] L. Chen, S. Fan, V. Kumar, and Y. Jia, “A method of human activity recognition in transitional period,” *Inf.*, vol. 11, no. 9, pp. 1–17, 2020, doi: 10.3390/INFO11090416.
- [59] I. T. J. Springer, “Principal Component Analysis, Second Edition.”
- [60] Z. Chen, C. Jiang, and L. Xie, “A Novel Ensemble ELM for Human Activity Recognition Using Smartphone Sensors,” *IEEE Trans. Ind. Informatics*, vol. 15, no. 5, pp. 2691–2699, 2019, doi: 10.1109/TII.2018.2869843.
- [61] Z. Chen, Q. Zhu, Y. C. Soh, and L. Zhang, “Robust Human Activity Recognition Using Smartphone Sensors via CT-PCA and Online SVM,” *IEEE Trans. Ind. Informatics*, vol. 13, no. 6, pp. 3070–3080, 2017, doi: 10.1109/TII.2017.2712746.
- [62] A. Jain and V. Kanhangad, “Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors,” *IEEE Sens. J.*, vol. 18, no. 3, pp. 1169–1177, 2018, doi: 10.1109/JSEN.2017.2782492.
- [63] C. Ma, W. Li, J. Cao, J. Du, Q. Li, and R. Gravina, “Adaptive sliding window based activity recognition for assisted livings,” *Inf. Fusion*, vol. 53, no. December 2018, pp. 55–65, 2020, doi: 10.1016/j.inffus.2019.06.013.
- [64] X. Zhou, “Wearable health monitoring system based on human motion state recognition,” *Comput. Commun.*, vol. 150, no. October 2019, pp. 62–71, 2020, doi: 10.1016/j.comcom.2019.11.008.
- [65] Z. Chen, S. Xiang, J. Ding, and X. Li, “Smartphone sensor-based human activity recognition using feature fusion and maximum full a posteriori,” *IEEE Trans. Instrum. Meas.*, vol. 69, no. 7, pp. 3992–4001, 2020, doi: 10.1109/TIM.2019.2945467.
- [66] R. Jansi and R. Amutha, “Hierarchical evolutionary classification framework for human action recognition using sparse dictionary optimization,” *Swarm Evol. Comput.*, vol. 63, no. October 2020, 2021, doi: 10.1016/j.swevo.2021.100873.
- [67] M. Webber and R. F. Rojas, “Human Activity Recognition with Accelerometer and Gyroscope: A Data Fusion Approach,” *IEEE Sens. J.*, vol. 21, no. 15, pp. 16979–16989, 2021, doi: 10.1109/JSEN.2021.3079883.
- [68] S. Liaqat *et al.*, “Novel Ensemble Algorithm for Multiple Activity Recognition in Elderly People Exploiting Ubiquitous Sensing Devices,” *IEEE Sens. J.*, vol. 21, no. 16, pp. 18214–18221, 2021, doi: 10.1109/JSEN.2021.3085362.
- [69] F. Krüger, “Activity, Context, and Plan Recognition with Computational Causal Behaviour Models,” *ResearchGate*, no. August, 2018, [Online]. Available: [https://www.researchgate.net/figure/Confusion-matrix-for-multi-class-classification-The-confusion-matrix-of-a\\_fig7\\_314116591](https://www.researchgate.net/figure/Confusion-matrix-for-multi-class-classification-The-confusion-matrix-of-a_fig7_314116591).
- [70] G. Marcus *et al.*, “Deep Learning: A Critical Appraisal,” Jan. 2018, Accessed: Nov. 07, 2021. [Online]. Available: <http://arxiv.org/abs/1801.00631>.
- [71] C.-J. Holst, “Utilising accelerometer and gyroscope in smartphone to detect incidents on a test track for cars Luleå tekniska universitet Institutionen för system-och rymdteknik,” 2017.
- [72] T. H. Lan, Z. Y. Gao, A. N. Abdalla, B. Cheng, and S. Wang, “Detrended fluctuation analysis as a statistical method to study ion single channel signal,” *Cell Biol. Int.*, vol. 32, no. 2, pp. 247–252, Feb. 2008, doi: 10.1016/J.CELLB.2007.09.001.