

PENGENALAN AKTIVITAS MANUSIA MENGGUNAKAN SENSOR AKSELEROMETER DAN GIROSKOP PADA *SMARTPHONE* DENGAN METODE *K-NEAREST NEIGHBOR*

Zainal Arifien¹, Fitra A. Bachtiar^{*2}, Novanto Yudistira³

^{1,2,3} Universitas Brawijaya, Malang

Email: ¹zainalarifien@student.ub.ac.id, ²fitra.bachtiar@ub.ac.id, ³yudistira@ub.ac.id

*Penulis Korespondensi

(Naskah masuk: 23 September 2021, diterima untuk diterbitkan: 31 Desember 2022)

Abstrak

Pengenalan aktivitas manusia atau *Human Activity Recognition* (HAR) merupakan salah satu topik yang populer karena besarnya peluang untuk diterapkan di kehidupan sehari-hari. Tujuan dari pengenalan ini adalah untuk mengenali, mendeteksi, dan mengklasifikasikan aktivitas yang dilakukan manusia. Pengenalan aktivitas manusia adalah salah satu teknologi penting untuk memantau dinamisme seseorang sehingga dapat bermanfaat di berbagai hal. Selain untuk menjaga kesehatan, pencegahan penyakit, dan membantu menentukan jenis olah raga, HAR dapat dimanfaatkan juga untuk diterapkan pada bidang keamanan dan pengembangan teknologi. Penelitian ini menggunakan *smartphone* sebagai teknologi utama dalam memperoleh data dengan memanfaatkan sensor akselerometer dan giroskop yang telah tertanam di dalamnya. Terdapat 8 macam aktivitas yang diteliti dengan kombinasi lama waktu eksperimen 5, 10, dan 15 detik serta posisi *smartphone* dipegang bebas maupun di dalam saku celana kanan. Data yang diperoleh terdiri dari 3 sumbu (x, y, dan z) pada setiap sensor yang digunakan. Data tersebut kemudian melalui proses pengolahan dan klasifikasi menggunakan algoritme *k-Nearest Neighbor* (*k-NN*). Hasil akurasi yang didapat dalam penelitian ini mencapai 79,56%. Hasil yang diperoleh melalui penelitian ini menunjukkan bahwa perbedaan peletakan *smartphone* mempengaruhi hasil pengenalan aktivitas manusia secara stabil. Selain itu, perbedaan jumlah data akibat perbedaan lamanya waktu eksperimen dapat mengakibatkan perbedaan lamanya waktu komputasi. Penelitian ini menjadi penting karena hasilnya dapat menjadi batu loncatan bagi penelitian selanjutnya. Beberapa peluang pengembangan juga dilampirkan pada bagian akhir.

Kata kunci: pengenalan aktivitas manusia, *k-NN*, *smartphone*, akselerometer, giroskop

HUMAN ACTIVITY RECOGNITION USING ACCELEROMETER AND GYROSCOPE SENSORS ON THE SMARTPHONE WITH K-NEAREST NEIGHBOR

Abstract

Human activity recognition (HAR) is one of the most popular topics because of the large opportunities for its application in life. The purpose of HAR is to recognize, detect and classify human activities. Human activity recognition is one of the important technologies for monitoring a person's dynamism so that it can be utilized in various ways. Apart from maintaining health, preventing disease, and helping determine the type of exercise, HAR can also be used to be applied in the field of security and technological developments. This study uses smartphones as the main technology in obtaining data by utilizing the built-in accelerometer and gyroscope sensors. There are 8 types of activities studied with a combination of 5, 10, and 15 seconds of experimental time and the position of the smartphone is carried freely or in the right trouser pocket. The data obtained consists of 3 axes (x, y, and z) on each sensor used. The data then processed and classified using the k-Nearest Neighbor (k-NN) algorithm. The accuracy results obtained in this study reaches 79.56%. The results obtained through this study indicate that differences in smartphone placement affect the results of human activity recognition stably. In addition, differences in the amount of data due to differences in the length of the experiment period can result in differences in the length of computation time. This research is important because the results can be used as material for further research assistance. Some development opportunities are also attached at the end.

Keywords: human activity recognition, *k-NN*, *smartphone*, accelerometer, gyroscope

1. PENDAHULUAN

Pengenalan Aktivitas Manusia atau *Human Activity Recognition* (HAR) merupakan salah satu topik yang populer (Zmitri, Fourati & Vuillerme, 2019) di kalangan peneliti akademis dan komersial karena besarnya peluang untuk diterapkan di kehidupan sehari-hari (Junita & Bachtiar, 2020). Tujuan dari HAR adalah untuk mengenali, mendeteksi, dan mengklasifikasikan aktivitas manusia. Pengenalan aktivitas manusia adalah salah satu teknologi penting untuk memantau dinamisme seseorang (Gulzar, Leema & Malaserene, 2019).

Beberapa manfaat yang dapat diperoleh pada bidang kesehatan adalah pembuatan sistem kesehatan dan manajemen olahraga (Fan, Wang & Wang, 2013) yang dapat membantu manusia menjaga kesehatannya. Hal ini dapat dilakukan dengan cara seperti mengenali berapa lama pengguna berolahraga, berjalan maupun beristirahat. HAR dalam bidang kesehatan juga dapat bermanfaat untuk pencegahan *office workers syndrome* (Paliyawan, Nukoolkit & Mongkolnam, 2014). HAR juga dapat digunakan untuk mengontrol tingkat kejahatan dengan melakukan pemantauan melalui kamera. Selain itu juga dapat dimanfaatkan untuk menciptakan lingkungan *smart home* yang dapat memudahkan aktivitas manusia (Jobanputra, Bavishi & Doshi, 2019).

Dengan semakin berkembangnya zaman, teknologi dapat digunakan sebagai alat bantu untuk melakukan pengenalan aktivitas manusia. Saat ini, *smartphone* merupakan salah satu benda berteknologi yang bisa ditemui kapan pun dan di mana pun karena manfaat dan kegunaannya yang dapat dirasakan. Selain sebagai media untuk mencari informasi, menonton video, mendengarkan musik, bersosialisasi, dan sebagainya (Usharani & Sakthivel, 2016), *smartphone* juga dapat digunakan untuk mengenali aktivitas yang dilakukan manusia.

Pada beberapa penelitian mengenai pengenalan aktivitas manusia, *smartphone* dipilih karena kemudahannya dalam penggunaan sehari-hari. *Smartphone* juga memiliki karakteristik seperti ukuran yang relatif kecil sehingga mudah untuk digunakan selagi melakukan aktivitas (Kharat, Walse & Dharaskar, 2017). Selain itu *smartphone* juga mudah digunakan sebagai alat bantu untuk memantau aktivitas kehidupan sehari-hari secara otomatis dan tidak mencolok (Anguita, Ghio, Oneto, Parra & Reyes-Ortiz, 2013). Hal ini dapat dicapai dengan dukungan teknik *machine learning* (Gulzar, Leema & Malaserene, 2019). Penggunaan *smartphone* dan teknik *machine learning* (dalam penelitian ini *k-Nearest Neighbor*) diyakini dapat mengatasi permasalahan HAR dengan keunggulan-keunggulan yang di miliki.

Sistematika penulisan terbagi menjadi beberapa bagian. Setelah bagian pendahuluan, bagian selanjutnya akan membahas mengenai beberapa penelitian yang telah dilakukan sebelumnya seputar

pengenalan aktivitas manusia atau *Human Activity Recognition* (HAR). Bagian ketiga akan membahas mengenai metode yang digunakan untuk klasifikasi, yaitu metode *k-Nearest Neighbor* (*k-NN*). Bagian keempat akan berisi metodologi yang digunakan dalam penelitian ini. Bagian selanjutnya adalah pembahasan mengenai hasil yang diperoleh serta kesimpulan dan *future work* atau peluang penelitian ke depan yang dapat dilakukan.

2. METODE PENELITIAN

2.1. Mekanisme Pengambilan Data

Penelitian ini bekerja sama dengan *Research Group Sistem Cerdas*, Fakultas Ilmu Komputer, Universitas Brawijaya (Laboratorium Sistem Cerdas | Fakultas Ilmu Komputer (FILKOM) Universitas Brawijaya, 2021). Pengambilan data primer dilakukan oleh 2 subjek dengan menggunakan *smartphone* Xiaomi Mi 8 (Mi Global Home, 2021) yang telah terinstall aplikasi aHar. Aplikasi aHar ini dapat diunduh pada situs penelitian aHar (<https://a-har.org/>, 2020). Aplikasi ini akan mencatat nilai dari sensor akselerometer dan giroskop ketika pengguna sedang beraktivitas. Subjek melakukan 8 aktivitas berbeda dengan mekanisme seperti pada Tabel 1.

Aktivitas-aktivitas tersebut dipilih berdasarkan penelitian sebelumnya yang dilakukan oleh (Anguita, Ghio, Oneto, Parra & Reyes-Ortiz, 2013) dengan penggantian aktivitas *Walk Downstairs* (3) dan *Walk Upstairs* (3) menjadi *Run* (1), *Jump* (1), *Run* (2), dan *Jump* (2). Penggunaan aktivitas *Run* telah digunakan pada beberapa penelitian sebelumnya, seperti (Ravi, Dandekar, Mysore & Littman, 2005) dan (Oniga & Suto, 2014). Sedangkan aktivitas *Jump* dimasukkan sebagai salah satu opsi pengembangan pada penelitian ini.

Tabel 1. Mekanisme Pengambilan Data Menggunakan *Smartphone*

Nomor	Aktivitas	Waktu (detik)
	<i>Start (Standing Position)</i>	
1	<i>Stand</i> (1)	5, 10, 15
	Istirahat	
2	<i>Sit</i> (1)	5, 10, 15
	Istirahat	
3	<i>Stand</i> (2)	5, 10, 15
	Istirahat	
4	<i>Lay Down</i> (1)	5, 10, 15
	Istirahat	
5	<i>Sit</i> (2)	5, 10, 15
	Istirahat	
6	<i>Lay Down</i> (2)	5, 10, 15
	Istirahat	
7	<i>Walk</i> (1)	5, 10, 15
	Istirahat	
8	<i>Walk</i> (2)	5, 10, 15
	Istirahat	
9	<i>Walk Downstairs</i> (1)	5, 10, 15
	Istirahat	
10	<i>Walk Upstairs</i> (1)	5, 10, 15
	Istirahat	
11	<i>Walk Downstairs</i> (2)	5, 10, 15
	Istirahat	
12	<i>Walk Upstairs</i> (2)	5, 10, 15
	Istirahat	
13	<i>Run</i> (1)	5, 10, 15

Nomor	Aktivitas	Waktu (detik)
14	<i>Jump</i> (1) Istirahat	5, 10, 15
15	<i>Run</i> (2) Istirahat	5, 10, 15
16	<i>Jump</i> (2) Istirahat <i>Stop</i>	5, 10, 15

Pada setiap nomor aktivitas, subjek melakukan beberapa tahapan. Tahap pertama adalah bersiap di posisi. Selanjutnya subjek menekan tombol *start* (terdapat jeda 5 detik hingga pengambilan data dimulai) sebelum melakukan aktivitas eksperimen. Setelah aktivitas pengambilan data selesai, subjek menekan tombol *sync* untuk melakukan sinkronisasi data dengan *database server*.

Penelitian ini menggunakan 2 macam posisi *smartphone* pada saat subjek melakukan eksperimen, yaitu di dalam saku celana kanan dengan peletakan menggunakan posisi *portrait* seperti pada Gambar 1 dan *smartphone* yang dipegang secara bebas oleh subjek. Data yang telah dikumpulkan selama eksperimen tersebut dapat diakses dan diunduh melalui situs penelitian aHar dengan ekstensi *file csv*.



Gambar 1. Posisi Peletakan *Smartphone* di dalam Saku Celana Kanan

Sumber: Diadaptasi dari google.com

2.2. Mekanisme Pengolahan Data

Pada tahap pengolahan, mekanisme yang digunakan adalah sebagai berikut:

1. Mengubah nama label menjadi angka.
2. Data yang diperoleh digabung berdasarkan lama waktu eksperimen dan posisi peletakan *smartphone* serta mengkodifikasi nama label.
3. Melakukan pengacakan urutan baris data pada data yang telah digabung.

Contoh label data asli dapat dilihat pada Tabel 2 yang berisi kodifikasi label data atau perubahan nama label. Tabel 3 berisi contoh data asli yang didapat dari situs aHar dengan karakter waktu eksperimen 5 detik, posisi *smartphone* bebas serta aktivitas *jump*. Tabel 4 merupakan hasil data menggunakan mekanisme pengolahan data nomor 2 dan 3 untuk waktu eksperimen 5 detik dan posisi *smartphone* bebas.

Mekanisme pengolahan data ini dilakukan pada setiap macam waktu dan posisi *smartphone*. Dengan demikian terdapat 6 data inti yaitu waktu 5, 10, dan 15 detik pada posisi *smartphone* bebas serta 5, 10, dan 15 detik pada posisi *smartphone* di letakkan di dalam saku celana kanan.

2.3. Mekanisme Klasifikasi Menggunakan Metode *K-NN*

Pada penelitian ini, nilai parameter untuk pelatihan *k-NN* yang digunakan adalah 70% data latih dan 30% data uji, nilai 1-10 untuk parameter *k*, dan perhitungan jarak *Euclidean* serta *Manhattan*. Perhitungan akurasi menggunakan fungsi *metrics.accuracy_score* pada program *python* dengan perbandingan jumlah data benar dibagi dengan jumlah total data.

Tabel 2. Kode Nama Label

Label Asli	Kode Label	Label Asli	Kode Label	Label Asli	Kode Label	Label Asli	Kode Label
<i>jumpbebas1</i>	1	<i>runbebas1</i>	5	<i>standbebas1</i>	9	<i>walkdownstairsbebas1</i>	13
<i>jumpbebas2</i>	2	<i>runbebas2</i>	6	<i>standbebas2</i>	10	<i>walkdownstairsbebas2</i>	14
<i>laydownbebas1</i>	3	<i>sitbebas1</i>	7	<i>walkbebas1</i>	11	<i>walkupstairsbebas1</i>	15
<i>laydownbebas2</i>	4	<i>sitbebas2</i>	8	<i>walkbebas2</i>	12	<i>walkupstairsbebas2</i>	16

Tabel 3. Contoh Data yang Diunduh dari Situs aHar

<i>gyro_x</i>	<i>gyro_y</i>	<i>gyro_z</i>	<i>acc_x</i>	<i>acc_y</i>	<i>acc_z</i>	label
-2,76316	-1,09002	-0,81367	-13,235	29,21051	21,99665	<i>jumpbebas1</i>
0,244847	0,782065	-0,64934	-3,54568	4,507661	7,817776	<i>jumpbebas1</i>
...
-1,32441	-1,97266	-0,21361	0,064907	20,11041	-1,85236	<i>jumpbebas1</i>

Tabel 4. Data Waktu Eksperimen 5 Detik dan Posisi *Smartphone* Bebas Setelah Mekanisme Pengolahan Data Nomor 2 dan 3

<i>gyro_x</i>	<i>gyro_y</i>	<i>gyro_z</i>	<i>acc_x</i>	<i>acc_y</i>	<i>acc_z</i>	label
2,330266	-5,27444	-1,22409	2,304306	18,9452	12,32412	5
-4,14359	-0,26304	-0,83551	-1,28712	20,4553	30,81892	2
...
1,240148	-0,75337	-2,01485	-7,24488	9,090646	19,41356	6

3. PENGENALAN AKTIVITAS MANUSIA

Berbagai penelitian telah dilakukan untuk mengenali aktivitas manusia. Beberapa penelitian

memilih menggunakan video atau gambar dari kamera untuk mengumpulkan data penelitian. Penelitian (Shahroudy, Liu, Ng & Wang, 2016)

berhasil memperoleh dataset yang terdiri dari 56.880 sampel video RGB + D. Data tersebut diperoleh dari 40 subjek manusia yang berbeda dengan bantuan Microsoft Kinect v2 untuk proses pengambilan data. Selain itu juga terdapat penelitian (Jaouedi, Boujnah, Htiwich & Bouhlel, 2016) yang menggunakan video dari dataset KTH (www.csc.kth.se/cvap/actions/, 2020) yang berjumlah 600 video.

Namun penelitian dengan menggunakan video mempunyai kekurangan, yaitu hanya terbatas pada sudut pandang yang mampu dicapai oleh kamera. Apabila subjek penelitian melewati atau tidak tercakup oleh sudut pandang kamera maka pengenalan aktivitas manusia pun tidak dapat dilakukan. Penelitian lain dilakukan dengan menggunakan sensor eksternal yang dipasang pada tubuh manusia. (Zmitri, Fourati & Vuillermé, 2019) menggunakan alat IMMUs (*Inertial and Magnetic Measurement Units*) yang terdiri dari sensor 3-axis *accelerometer*, 3-axis *gyroscope*, dan 3-axis magnetometer. Sebanyak 5 IMMUs digunakan dan diletakkan di berbagai tubuh subjek manusia. Namun penggunaan sensor eksternal yang dipasang pada tubuh manusia juga memiliki kendala, di antaranya adalah membuat pengguna tidak nyaman dan tidak memberikan solusi jangka panjang untuk pemantauan aktivitas, seperti ketika pemasangan alat kembali setelah selesai atau akan digunakan kembali (Anguita, Ghio, Oneto, Parra & Reyes-Ortiz, 2013).

Berdasarkan kendala-kendala yang dihadapi melalui pengambilan data menggunakan video, gambar, dan sensor eksternal tersebut maka dibutuhkan sebuah cara untuk mengatasi hal tersebut. Salah satu cara lain yang dapat dilakukan untuk HAR adalah dengan menggunakan sensor yang telah tertanam pada *smartphone*. Saat ini *smartphone* telah dilengkapi dengan berbagai sensor seperti akselerometer, giroskop, magnetometer, *Global Positioning System* (GPS), kompas, barometer, dan sebagainya.

Sensor akselerometer pada *smartphone* digunakan pada penelitian (Kaghyan & Sarukhanyan, 2012; Paul & George, 2015; Usharani & Sakthivel, 2016; Fan, Wang & Wang, 2013; Bieber, Luthardt, Peter & Urban, 2011). Kombinasi dengan sensor giroskop pada penelitian juga digunakan oleh (Batool, Jalal & Kim, 2019; Ha & Choi, 2016). Kombinasi dengan sensor lain juga telah diterapkan untuk mengumpulkan data, seperti magnetometer dan gps (Garcia-Gonzalez, Rivero, Fernandez-Blanco & Luaces, 2020).

4. K-NEAREST NEIGHBOR

K-Nearest Neighbor (k -NN) adalah algoritme pembelajaran *supervised* di mana hasil dari *query instance* baru diklasifikasikan berdasarkan mayoritas nilai kategori pada k -NN (Kaghyan & Sarukhanyan, 2012; Paul & George, 2015; Usharani & Sakthivel, 2016). Algoritme k -NN adalah salah satu yang paling

sederhana dari semua algoritme pembelajaran mesin (Paul & George, 2015) yang bertujuan untuk menyimpan semua yang tersedia dan mengklasifikasikan objek baru berdasarkan atribut dan sampel pelatihan.

Pada fase pembelajaran, k -NN melakukan penyimpanan vektor-vektor fitur dan klasifikasi dari data pembelajaran. Pada fase klasifikasi, fitur-fitur yang sama dihitung untuk objek yang akan diuji (Baharuddin, Hasanuddin & Azis, 2019). Objek tersebut akan diklasifikasikan berdasarkan suara mayoritas dari tetangganya (k). Ada beberapa cara untuk menghitung jarak pada k -NN, di antaranya adalah menggunakan *Euclidean* (Persamaan 1), *Manhattan* (Persamaan 2), *Minkowski* (Persamaan 3), dan *Chebyshev* (Persamaan 4) (Wahyono, Trisna, Sariwening, Fajar & Wijayanto, 2020).

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

$$D(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (2)$$

$$D(x, y) = (\sum_{i=1}^n |x_i - y_i|^r)^{1/r} \quad (3)$$

$$D(x, y) = \max_{i=1}^n |x_i - y_i| \quad (4)$$

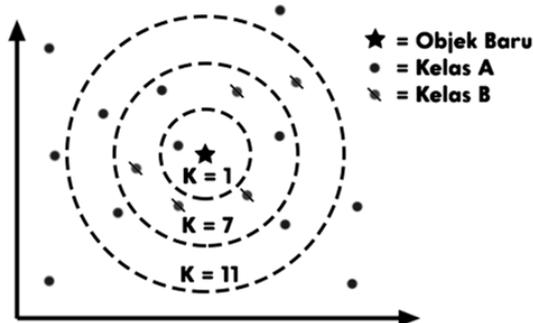
Pada persamaan 1 hingga 4, nilai jarak dihitung antara x dan y yang merupakan objek dan data tetangga. Nilai r pada persamaan *Minkowski* berisi nilai selain 1 dan 2 karena nilai apabila berisi nilai 1 maka akan ditemukan rumus *Manhattan* dan apabila berisi nilai 2 maka akan ditemukan rumus *Euclidean*. Sebagai contoh, apabila data uji A dengan 4 fitur (B, C, D, dan E) dan akan dicari kelasnya menggunakan rumus *Euclidean* maka akan menjadi seperti berikut:

$$D(x, A) = \sqrt{(x_1 - B)^2 + (x_2 - C)^2 + (x_3 - D)^2 + (x_4 - E)^2} \quad (5)$$

Perhitungan nilai jarak dari objek A dengan data latih tersebut akan diulang kepada seluruh data latih yang dimiliki. Langkah selanjutnya adalah mengurutkan nilai jarak antara objek A dengan seluruh data latih yang telah dihitung, semakin kecil jarak maka akan semakin dekat dengan objek yang sedang dicari kelasnya. Perhitungan pencarian kelas pada k -NN, menggunakan nilai k .

Jika nilai k adalah 1 maka objek tersebut akan mencari 1 kelas tetangga terdekatnya. Begitu pula apabila nilai k adalah 10, maka objek tersebut akan mencari 10 kelas tetangga terdekatnya untuk kemudian memilih kelas mayoritas sebagai kelas objek tersebut. Ilustrasinya dapat dilihat pada Gambar 1. Pada $k = 1$, objek baru yang belum diketahui memiliki tetangga terdekat kelas A. Sedangkan pada $k = 7$, objek baru memiliki tetangga dengan mayoritas kelas B. Begitu pula ketika nilai $k = 11$ maka objek akan termasuk ke dalam kelas A karena mayoritas tetangga merupakan kelas A. Dengan demikian nilai

k sangat mempengaruhi hasil klasifikasi pada algoritme k -NN.



Gambar 2. Ilustrasi Nilai K Algoritme K -NN

Penelitian ini menggunakan persamaan *Euclidean* dan *Manhattan* untuk menghitung jarak ketetanggaan karena persamaan tersebut merupakan yang paling banyak digunakan pada penelitian (Hu, Huang, Ke & Tsai, 2016)

5. HASIL DAN PEMBAHASAN

Tabel 5, Tabel 6, dan Tabel 7 berturut-turut merupakan hasil akurasi pengenalan aktivitas manusia menggunakan k -NN dengan lama waktu eksperimen 5, 10, dan 15 detik. Nilai yang dicetak tebal merupakan nilai akurasi tertinggi pada nilai k tertentu di setiap lama waktu eksperimen yang dilakukan, baik ketika menggunakan persamaan *Manhattan* maupun *Euclidean*.

Dapat diamati pada ketiga tabel tersebut bahwa posisi *smartphone* ketika dipegang bebas selalu memiliki akurasi lebih tinggi daripada ketika *smartphone* diletakkan di dalam saku celana kanan, baik menggunakan perhitungan *Manhattan* maupun *Euclidean*. Hal ini mungkin dapat terjadi karena pada saat *smartphone* dipegang bebas, nilai yang diperoleh sensor akselerometer dan giroskop memiliki karakteristik yang lebih "tegas" daripada ketika *smartphone* diletakkan di dalam saku celana kanan yang mungkin lebih "samar".

Selain itu dapat diamati pula bahwa nilai $k = 1$ memiliki nilai akurasi tertinggi di setiap tabel berdasarkan jenis perhitungan jarak dan peletakan *smartphone* yang digunakan. Nilai akurasi yang didapat pada penggunaan nilai $k = 2$ sampai dengan 10 tidak mampu mencapai akurasi yang diperoleh $k = 1$. Dengan kata lain, penggunaan nilai tetangga terdekat memiliki kemampuan untuk mengenali kelas lebih baik dari pada menggunakan jumlah tetangga lebih besar.

Dari ketiga macam waktu eksperimen yang digunakan, waktu eksperimen selama 15 detik memiliki nilai akurasi tertinggi pada $k = 1$. Hal ini menunjukkan bahwa semakin lama waktu

eksperimen maka akan menghasilkan data yang semakin banyak untuk diolah oleh metode k -NN sehingga mampu memperoleh nilai akurasi yang lebih baik.

Tabel 5. Hasil Akurasi Aktivitas dengan Waktu 5 Detik (dalam %)

K	Manhattan		Euclidean	
	Bebas	Saku	Bebas	Saku
1	76,1176	69,8413	75,2941	68,9342
2	70,7059	68,254	69,5294	67,2336
3	73,7647	68,254	71,8824	67,0068
4	72,8235	69,0476	69,8824	67,8005
5	73,6471	67,6871	71,5294	66,6667
6	71,6471	67,1202	70,0	66,6667
7	71,5294	66,78	70,3529	64,966
8	70,4706	66,2132	69,0588	65,3061
9	71,7647	66,4399	70,0	64,7392
10	70,7059	65,5329	68,9412	64,6259

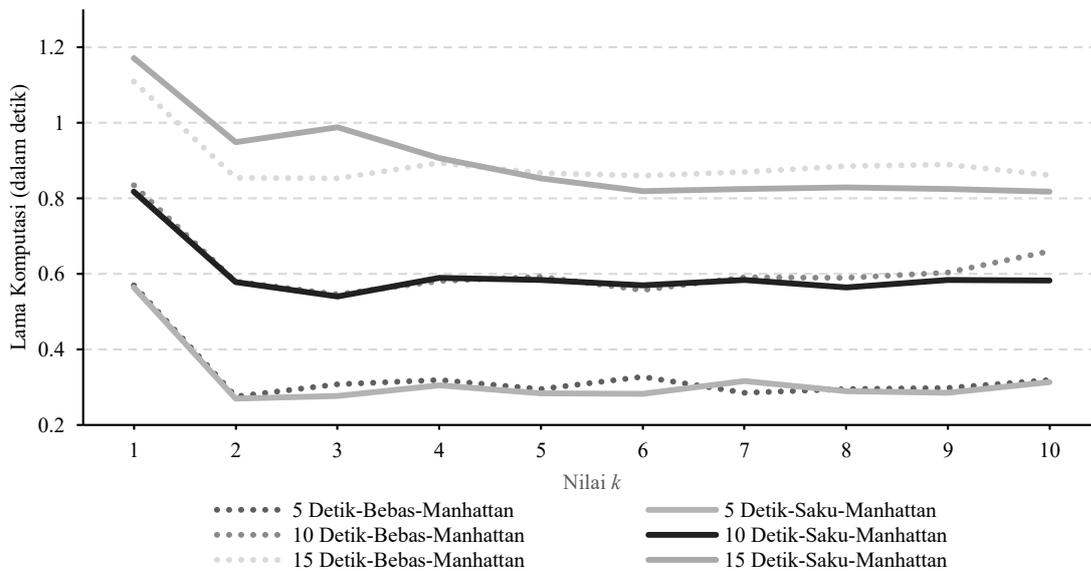
Tabel 6. Hasil Akurasi Aktivitas dengan Waktu 10 Detik (dalam %)

K	Manhattan		Euclidean	
	Bebas	Saku	Bebas	Saku
1	77,6352	64,1595	76,5756	63,0199
2	72,56	62,3932	72,56	61,1396
3	73,3965	62,5071	73,285	61,7664
4	72,783	62,849	73,3408	62,5071
5	73,7869	62,1652	73,0619	62,3932
6	72,783	61,9373	71,7791	62,3362
7	72,5042	61,7094	71,8349	61,8803
8	72,1138	61,4245	71,2214	61,7664
9	71,5561	62,3932	71,2214	62,2222
10	71,5561	61,9373	71,1099	61,8803

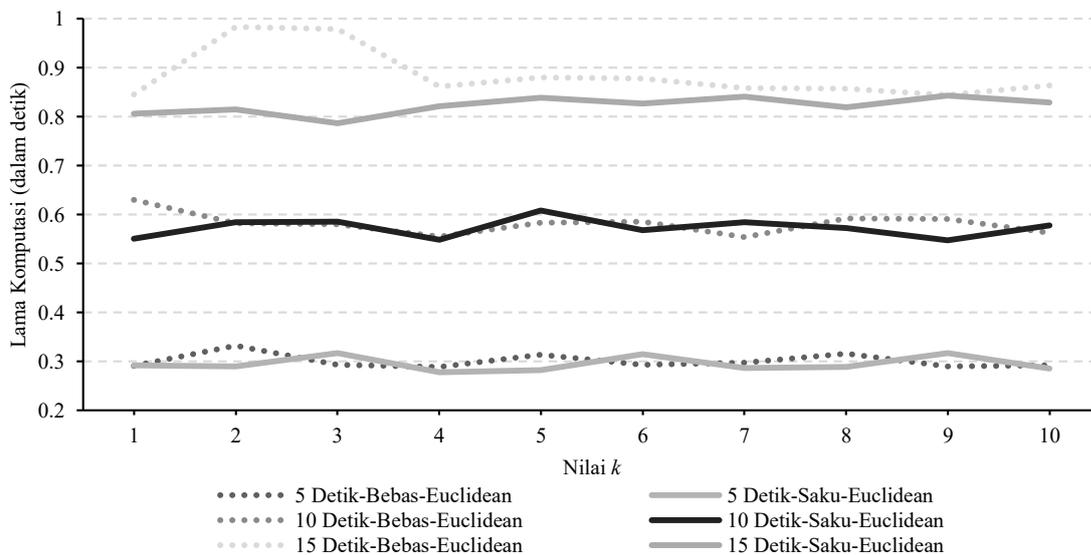
Tabel 7. Hasil Akurasi Aktivitas dengan Waktu 15 Detik (dalam %)

K	Manhattan		Euclidean	
	Bebas	Saku	Bebas	Saku
1	79,5631	70,3589	79,304	70,4361
2	75,7127	67,2327	75,2684	67,7731
3	77,0455	68,545	76,5642	69,0853
4	76,6013	69,3941	75,8608	68,9695
5	76,231	69,0853	75,7867	69,3169
6	76,194	69,6256	75,4906	68,6993
7	75,9719	70,0888	75,3054	68,545
8	76,6013	69,7028	75,6387	68,7765
9	75,8978	69,7414	74,9352	68,8923
10	75,4906	69,3555	75,1203	68,545

Gambar 3 dan Gambar 4 merupakan tampilan grafik waktu komputasi pengenalan aktivitas manusia menggunakan k -NN. Dapat diamati bahwa semakin lama waktu pengambilan data atau eksperimen maka akan mempengaruhi lamanya waktu komputasi. Hal ini terjadi kepada kedua macam perhitungan jarak, yaitu Manhattan maupun Euclidean. Lamanya proses komputasi tersebut terjadi karena perhitungan menggunakan algoritme k -NN, memerlukan perhitungan antara 1 objek *testing* dengan seluruh objek data *training* yang dimiliki pada dataset tersebut.



Gambar 3. Waktu Komputasi Menggunakan Perhitungan Jarak *Manhattan*



Gambar 4. Waktu Komputasi Menggunakan Perhitungan Jarak *Euclidean*

6. KESIMPULAN

Penelitian ini menggunakan dataset baru yang diperoleh melalui sensor akselerometer dan giroskop aplikasi aHar. Berdasarkan hasil penelitian ini, dapat diketahui bahwa pengambilan data dengan posisi *smartphone* dipegang bebas memiliki akurasi lebih tinggi daripada ketika diletakkan di dalam saku celana kanan yang mempengaruhi karakteristik “ketegasan” data. Selain itu, seiring lamanya waktu eksperimen maka waktu komputasi metode *k*-NN untuk mengenali aktivitas yang dilakukan juga akan semakin lama. Meskipun demikian, hasil akurasi dengan waktu eksperimen terlama (15 detik) memiliki hasil akurasi terbaik dengan nilai akurasi 79,5631%.

Hasil akurasi terbaik yang diperoleh berdasarkan penelitian ini masih di bawah dari hasil akurasi yang diperoleh oleh penelitian (Anguita,

Ghio, Oneto, Parra & Reyes-Ortiz, 2013) yang menjadi rujukan utama penelitian ini. Hal ini membutuhkan studi lebih lanjut mulai dari cara pengambilan data *raw*, pengolahan atau ekstraksi data *raw*, hingga pemilihan metode yang akan digunakan untuk melakukan pengenalan aktivitas manusia.

Penelitian ini memiliki banyak peluang untuk dikembangkan, di antaranya bagaimana cara untuk mendapatkan data *raw* yang akan digunakan pada penelitian, seperti penggunaan sensor lain pada *smartphone* (magnetometer, gps, dan sebagainya). Lalu dari segi ekstraksi pada data *raw* seperti nilai maksimal, nilai minimal, *standard deviation*, dan sebagainya. Selain itu bermacam-macam aktivitas juga dapat ditambahkan, seperti aktivitas transisi yaitu perpindahan dari *stand* menuju *sit*, atau *stand* menuju *walk*, dan sebagainya.

DAFTAR PUSTAKA

- ANGUITA, D., GHIO, A., ONETO, L., PARRA, X. dan REYES-ORTIZ, J.L., 2013. A Public Domain Dataset for Human Activity Recognition Using Smartphones. European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN). [online] Bruges (Belgium).pp.437–442. Tersedia melalui: <<https://www.kaggle.com/uciml/human-activity-recognition-with-smartphones>> [Diakses 12 Mar. 2020].
- ANON 2021. Mi Global Home. [online] Tersedia melalui: <<https://www.mi.com/global/mi8/>> [Diakses 28 May 2021].
- ANON 2021. Laboratorium Sistem Cerdas | Fakultas Ilmu Komputer (FILKOM) Universitas Brawijaya. [online] Tersedia melalui: <<https://filkom.ub.ac.id/legacy/unit/lab/labs>> [Diakses 23 Jul. 2021].
- BAHARUDDIN, M.M., HASANUDDIN, T. dan AZIS, H., 2019. ANALISIS PERFORMA METODE K-NEAREST NEIGHBOR UNTUK IDENTIFIKASI JENIS KACA. ILKOM Jurnal Ilmiah, [online] 11(3), pp.269–274. Tersedia melalui: <<http://jurnal.fikom.umi.ac.id/index.php/ILKOM/article/view/489>>.
- BATOOL, M., JALAL, A. dan KIM, K., 2019. Sensors Technologies for Human Activity Analysis Based on SVM Optimized by PSO Algorithm. 2019 International Conference on Applied and Engineering Mathematics (ICAEM). [online] IEEE.pp.145–150. Tersedia melalui: <<https://ieeexplore.ieee.org/document/8853770/>>.
- BIEBER, G., LUTHARDT, A., PETER, C. dan URBAN, B., 2011. The Hearing Trousers Pocket – Activity Recognition by Alternative Sensors. ACM International Conference Proceeding Series.
- FAN, L., WANG, Z. dan WANG, H., 2013. Human Activity Recognition Model Based on Decision Tree. 2013 International Conference on Advanced Cloud and Big Data. [online] IEEE.pp.64–68. Tersedia melalui: <<http://ieeexplore.ieee.org/document/6824574/>>.
- GARCIA-GONZALEZ, D., RIVERO, D., FERNANDEZ-BLANCO, E. dan LUACES, M.R., 2020. A Public Domain Dataset for Real-Life Human Activity Recognition Using Smartphone Sensors. Sensors, [online] 20(8), pp.1–14. Tersedia melalui: <<https://www.mdpi.com/1424-8220/20/8/2200>>.
- GULZAR, Z., LEEMA, A.A. dan MALASERENE, I., 2019. Human Activity Analysis using Machine Learning Classification Techniques. International Journal of Innovative Technology and Exploring Engineering, [online] 9(2), pp.3252–3258. Tersedia melalui: <<https://www.ijitee.org/wp-content/uploads/papers/v9i2/B7381129219.pdf>>.
- HA, S. dan CHOI, S., 2016. Convolutional Neural Networks for Human Activity Recognition using Multiple Accelerometer and Gyroscope Sensors. 2016 International Joint Conference on Neural Networks (IJCNN). [online] IEEE.pp.381–388. Tersedia melalui: <<http://ieeexplore.ieee.org/document/7727224/>>.
- <https://a-har.org/>, 2020. aHAR - affective-Human Activity Recognition. [online] Tersedia melalui: <<https://a-har.org/>> [Diakses 20 Sep. 2020].
- HU, L.-Y., HUANG, M.-W., KE, S.-W. dan TSAI, C.-F., 2016. The distance function effect on k-nearest neighbor classification for medical datasets. SpringerPlus, [online] 5(1), p.1304. Tersedia melalui: <<http://springerplus.springeropen.com/articles/10.1186/s40064-016-2941-7>>.
- JAOUEDI, N., BOUJNAH, N., HTIWICH, O. dan BOUHLEL, M.S., 2016. Human action recognition to human behavior analysis. 2016 7th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT). [online] IEEE.pp.263–266. Tersedia melalui: <<http://ieeexplore.ieee.org/document/7939877/>>.
- JOBANPUTRA, C., BAVISHI, J. dan DOSHI, N., 2019. Human Activity Recognition: A Survey. Procedia Computer Science, [online] 155, pp.698–703. Tersedia melalui: <<https://doi.org/10.1016/j.procs.2019.08.100>>.
- JUNITA, V. dan BACHTIAR, F.A., 2020. Klasifikasi Aktivitas Manusia menggunakan Algoritme Decision Tree C4.5 dan Information Gain untuk Seleksi Fitur. Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, [online] 3(10), pp.9426–9433. Tersedia melalui: <<http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/6446>>.

- KAGHYAN, S. dan SARUKHANYAN, H., 2012. Activity recognition using K-nearest neighbor algorithm on smartphone with Tri-axial accelerometer. *International Journal of Informatics Models and Analysis*, [online] 1, pp.146–156. Tersedia melalui: <<http://www.foibg.com/ijima/vol01/ijima01-2-p06.pdf>>.
- KHARAT, M. V, WALSE, K.H. dan DHARASKAR, R. V, 2017. Survey on Soft Computing Approaches for Human Activity Recognition. *International Journal of Science and Research*, [online] 6(2), pp.1328–1334. Tersedia melalui: <www.ijsr.net>.
- ONIGA, S. dan SUTO, J., 2014. Human activity recognition using neural networks. *Proceedings of the 2014 15th International Carpathian Control Conference (ICCC)*. [online] IEEE.pp.403–406. Tersedia melalui: <<http://ieeexplore.ieee.org/document/6843636/>>.
- PALIYAWAN, P., NUKOOLKIT, C. dan MONGKOLNAM, P., 2014. Prolonged sitting detection for office workers syndrome prevention using kinect. 2014 11th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). [online] IEEE.pp.1–6. Tersedia melalui: <<http://ieeexplore.ieee.org/document/6839785/>>.
- PAUL, P. dan GEORGE, T., 2015. An effective approach for human activity recognition on smartphone. 2015 IEEE International Conference on Engineering and Technology (ICETECH). [online] Coimbatore, TN, India: IEEE.pp.1–3. Tersedia melalui: <<http://ieeexplore.ieee.org/document/7275024/>>.
- RAVI, N., DANDEKAR, N., MYSORE, P. dan LITTMAN, M.L., 2005. Activity Recognition from Accelerometer Data. *Proceedings of the Seventeenth Conference on Innovative Applications of Artificial Intelligence*. Pittsburgh, Pennsylvania, USA.pp.1541–1546.
- SHAHROUDY, A., LIU, J., NG, T.-T. dan WANG, G., 2016. NTU RGB+D: A Large Scale Dataset for 3D Human Activity Analysis. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [online] IEEE.pp.1–10. Tersedia melalui: <<http://ieeexplore.ieee.org/document/7780484/>>.
- USHARANI, J. dan SAKTHIVEL, U., 2016. Human Activity Recognition using Android Smartphone. *International Journal of Advanced Networking & Applications*, (Special Issue-1st International Conference on “Innovations in Computing & Networking” (ICICN-2016) held at RajaRajeswari College of Engineering, Bangalore), pp.191–197.
- WAHYONO, W., TRISNA, I.N.P., SARIWENING, S.L., FAJAR, M. dan WIJAYANTO, D., 2020. Perbandingan penghitungan jarak pada k-nearest neighbour dalam klasifikasi data tekstual. *Jurnal Teknologi dan Sistem Komputer*, [online] 8(1), pp.54–58. Tersedia melalui: <<https://jtsiskom.undip.ac.id/index.php/jtsiskom/article/view/13387>>.
- www.csc.kth.se/cvap/actions/, 2020. Recognition of human actions. [online] Tersedia melalui: <<https://www.csc.kth.se/cvap/actions/>> [Diakses 25 Nov. 2020].
- ZMITRI, M., FOURATI, H. dan VUILLERME, N., 2019. Human Activities and Postures Recognition: From Inertial Measurements to Quaternion-Based Approaches. *Sensors*, [online] 19(19), pp.1–18. Tersedia melalui: <<https://www.mdpi.com/1424-8220/19/19/4058>>.