

**Studi Algoritma Klasifikasi Sensor *Accelerometer* dan *Gyroscope*
untuk Pola *Activity Daily Life* (ADL) pada Dewasa Sehat**

Tugas Akhir

diajukan untuk memenuhi salah satu syarat

memperoleh gelar sarjana

dari Program Studi S1 Teknik Informatika

Fakultas Informatika

Universitas Telkom

1301140315

Andika Nugroho Putra



Program Studi Sarjana S1 Teknik Informatika

Fakultas Informatika

Universitas Telkom

Bandung

2018

LEMBAR PENGESAHAN

Studi Algoritma Klasifikasi Sensor *Accelerometer* dan *Gyroscope* untuk Pola *Activity Daily Life* (ADL) pada Dewasa Sehat

Study Classification Algorithm of Accelerometer and Gyroscope Sensor for Activity Daily Life

NIM :1301140315

Andika Nugroho Putra

Tugas akhir ini telah diterima dan disahkan untuk memenuhi sebagian syarat memperoleh gelar pada Program Studi Sarjana S1 Teknik Informatika

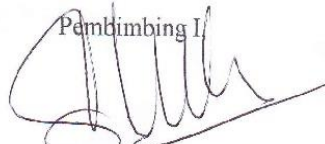
Fakultas Informatika

Universitas Telkom

Bandung, 6 Agustus 2018

Menyetujui

Pembimbing I,



Satria Mandala, S.T., M.Sc., Ph.D.

NIP : 16730040

Pembimbing II,



Irma Ruslina Defi, dr., SpKFR, PhD

NIP : 197412182014122001

Ketua Program Studi
Sarjana Teknik Informatika,



Said Al Faraby, S.T., M.Sc

NIP : 15890019

LEMBAR PERNYATAAN

Dengan ini saya, Andika Nugroho Putra, menyatakan sesungguhnya bahwa Tugas Akhir saya dengan judul "**Studi Algoritma Klasifikasi Sensor *Accelerometer* dan *Gyroscope* untuk Pola *Activity Daily Life* (ADL) pada Dewasa Sehat**" beserta dengan seluruh isinya adalah merupakan hasil karya sendiri, dan saya tidak melakukan penjiplakan yang tidak sesuai dengan etika keilmuan yang berlaku dalam masyarakat keilmuan. Saya siap menanggung resiko/sanksi yang diberikan jika di kemudian hari ditemukan pelanggaran terhadap etika keilmuan dalam buku TA atau jika ada klaim dari pihak lain terhadap keaslian karya,

Bandung, 6 Agustus 2018

Yang Menyatakan



Andika Nugroho Putra

Studi Algoritma Klasifikasi Sensor *Accelerometer* dan *Gyroscope* untuk Pola *Activity Daily Life* (ADL) pada Dewasa Sehat

Andika Nugroho Putra¹, Satria Mandala², Irma Ruslina Defi³

Fakultas Informatika, Universitas Telkom, Bandung

¹andika.dikanp@students.telkomuniversity.ac.id, ²satriamandala@telkomuniversity.ac.id,

³irmaruslina@gmail.com

Abstrak

Sistem klasifikasi *Activity Daily Life* (ADL) ini adalah sistem untuk klasifikasi aktivitas yang dilakukan seseorang dengan menggunakan *wearable sensor* untuk membantu lansia sehingga aman dan nyaman dalam melakukan aktivitasnya sehari-hari. Sistem klasifikasi ADL dengan menggunakan sensor *accelerometer* dan *gyroscope* banyak menggunakan berbagai algoritma untuk klasifikasinya, seperti algoritma *K-Nearest Neighbour* (KNN), *Support Vektor Machine* (SVM) dan sebagainya. Tugas akhir ini bermaksud untuk mencari tingkat akurasi yang terbaik beserta spesifitas dan sensitivitasnya dengan membandingkan beberapa algoritma klasifikasi dengan menggunakan dataset yang telah dibuat dengan alat yang terdiri dari mikrokontroler ESP32 berbasis sensor MPU-6050 (sensor *accelerometer* dan *gyroscope*) dan akan menguji 5 ADL yaitu berjalan, naik tangga, turun tangga, berdiri, dan duduk. Data yang didapat dari alat kemudian akan diklasifikasi untuk mengenali ADL yang dilakukan. Hasil yang didapatkan adalah ketiga algoritma sudah baik melakukan klasifikasi dengan akurasi mencapai 95%. KNN menjadi algoritma terbaik untuk klasifikasi ADL dengan menghasilkan akurasi sebesar 97,33%.

Kata kunci : Klasifikasi *Multiclass*, ADL, *Accelerometer*, *Gyroscope*, KNN

Abstract

Classification system for activity daily life (ADL) is a system who classified human activity using wearable sensor to help elderly doing their activity safely and comfortably. Classifier for ADL using accelerometer and gyroscope sensor usually used classification algorithm like K-Nearest Neighbour, Support Vektor Machine, and many others. This final project aims to get high accuracy by using 1 tool that using ESP32 microcontroller and MPU-6050 sensor (accelerometer and gyroscope sensor) and will test 5 ADL like walking, walking upstairs, walking downstairs, standing, and sitting. The data obtained from the tool will be classified to recognition ADL. The result is the three algorithm have good accuracy up to 95%. KNN get the best algorithm for ADL classification with value of 97,33%

Keywords: Activity Daily Life, Multiclass Classification, Accelerometer, Gyroscope, KNN.

1. Pendahuluan

Latar Belakang

Di era globalisasi ini, pertumbuhan orang lanjut usia (lansia) semakin bertambah. Pada tahun 2014, jumlah penduduk di atas 60 tahun di Indonesia sudah mencapai angka 20,24 juta jiwa, setara dengan 8,03 persen dari seluruh penduduk Indonesia berdasarkan data Susenas 2014[1]. Jumlah sebanyak itu akan menjadi bahaya jika para lansia tersebut tidak diawasi dengan baik, ketika para lansia tersebut sedang melakukan aktivitas sehari-hari yang biasa disebut *activity daily life* (ADL). ADL seperti berjalan, berdiri, ataupun duduk pada lansia dapat membahayakan dikarenakan titik keseimbangan (*central of gravity*) para lansia sudah terganggu baik secara eksternal dan internal sehingga menyebabkan lansia mempunyai risiko jatuh yang tinggi. Insiden terjatuh untuk orang biasa mungkin tidaklah membahayakan karena hanya berdampak kecil terhadap tubuh mereka, tetapi insiden terjatuh untuk orang lansia tidaklah sama seperti yang dihadapi oleh orang biasa karena tubuh orang lansia sudah sangat lemah atau rapuh sehingga dampak dari terjatuh bisa menjadi hal yang sangat membahayakan. Insiden terjatuh biasanya terjadi karena hilangnya keseimbangan pada seseorang baik ketika orang tersebut sedang tidur, berdiri, duduk, maupun ketika orang tersebut sedang berjalan. Oleh karena itu insiden jatuh sudah menjadi masalah umum yang ditemui di sekitar kita.

Dengan perkembangan teknologi yang semakin pesat ini, maka insiden tersebut dapat diminimalisir terutama untuk para lansia dengan cara mengklasifikasi aktivitas yang sedang dilakukan oleh seseorang. Klasifikasi untuk ADL sangatlah penting untuk menyediakan bantuan terhadap lansia yang hidup sendiri atau orang berkebutuhan khusus dikarenakan dapat mengetahui ketika ada situasi yang tidak biasa dan menghindarkan dari kejadian yang berbahaya[2]. Rekognisi ADL dapat membantu mengawasi orang lansia dalam aktivitasnya sehari-hari sehingga meningkatkan tingkat keamanan, kenyamanan, dan kemandirian mereka. Pendeteksian aktivitas manusia tersebut bisa dilakukan dengan beberapa macam metode seperti menggunakan *wearable sensor* ataupun dengan menggunakan kamera. Akan tetapi, rekognisi ADL saat ini

masih kurang optimal dikarenakan belum mencoba pada banyak subyek sehingga dataset dari percobaan sebelumnya tidak bisa digeneralisir dan masih menggunakan beberapa alat sensor yang diletakkan di beberapa bagian tubuh.

Berdasarkan permasalahan di atas, maka akan dibangun sebuah alat dengan menggunakan mikrokontroler ESP32 dan sensor *accelerometer* dan *gyroscope* yang ada di MPU-6050 untuk mengklasifikasi ADL dengan melihat dari pola pergerakan seseorang tersebut. Alat ini akan dipasang di bagian tubuh seseorang yang akan melakukan aktivitas. Penelitian tugas akhir ini akan meneliti 5 aktivitas yaitu berdiri, duduk, berjalan, naik tangga dan turun tangga sehingga akan dibuat dataset yang terbagi ke dalam 5 kelas tersebut. Data yang telah didapat dari sensor-sensor alat tersebut akan diklasifikasi menggunakan beberapa algoritma klasifikasi yaitu algoritma KNN, SVM *One vs One*, SVM *One vs All*, dan *Naïve Bayes*.

Topik dan Batasannya

Masalah yang dibahas pada tugas akhir ini adalah :

1. Bagaimana cara membangun sistem dengan menerapkan algoritma klasifikasi untuk mengklasifikasikan aktivitas manusia yang sedang dilakukan berdasarkan data dari sensor *accelerometer* dan *gyroscopenya*?
2. Bagaimana tingkat akurasi yang dihasilkan dari algoritma yang digunakan?
3. Algoritma klasifikasi apa yang terbaik untuk klasifikasi ADL?

Batasan masalah yang digunakan dalam tugas akhir ini adalah :

1. Mikrokontroler yang digunakan adalah ESP32.
2. Memakai sensor *Accelerometer* dan *Gyroscope*.
3. Pengujian dilakukan di dalam ruangan (*indoor*), tidak *outdoor*.
4. Menggunakan 4 macam algoritma klasifikasi untuk klasifikasi ADL.
5. Melakukan pengujian KNN dengan k dari 1 hingga 10
6. Melakukan 5 pengujian aktivitas manusia yaitu “Berjalan”, “Berdiri”, “Turun Tangga”, “Naik Tangga” dan “Duduk”.
7. Aktivitas yang diklasifikasikan oleh sistem terbagi menjadi 5 kelas yaitu “Berjalan”, “Berdiri”, “Turun Tangga”, “Naik Tangga” dan “Duduk”.

Tujuan

1. Membangun sistem untuk klasifikasi ADL.
2. Mengetahui tingkat akurasi yang dihasilkan oleh sistem tersebut.
3. Mengetahui algoritma terbaik untuk klasifikasi ADL.

Organisasi Tulisan

Pada bagian 1 dijelaskan latar belakang dari masalah, rumusan masalah dan tujuan dari penelitian. Bagian 2 menjelaskan landasan teori yang terkait dengan penelitian ini. Bagian 3 menjelaskan implementasi dari metode yang digunakan. Bagian 4 menjelaskan mengenai pengujian dari implementasi metode tersebut. Serta bagian 5 merupakan kesimpulan.

2. Studi Terkait

Penelitian terhadap klasifikasi ADL telah banyak dilakukan. Muhammad Zubair, Kibong Song, dan Changwoo Yoon(2016) melakukan percobaan dengan menggunakan 4 subyek yaitu 2 laki-laki dan 2 perempuan dewasa dan sehat. Percobaan tersebut menggunakan 4 sensor *accelerometer* yang diletakkan di 4 posisi yang berbeda (Pinggang, paha kiri, pergelangan kaki kanan, tangan kanan) lalu mengklasifikasikannya dengan menggunakan algoritma *Random Forest* dan C4.5. Berdasarkan percobaan tersebut telah didapatkan bahwa algoritma *Random Forest* lebih baik dan C4.5 dengan akurasi sebesar 99,8%. Akan tetapi percobaan tersebut akan merepotkan *user* dikarenakan terlalu banyak menggunakan sensor yang diletakkan di 4 bagian tubuh yang berbeda[3].

Charlene, V. San Buenaventura, Nestor Michael(2017) melakukan klasifikasi ADL dengan menggunakan 3 sensor yaitu *accelerometer*, *gyroscope*, dan *magnetometer*. Percobaan tersebut menggunakan 4 subyek laki-laki dan memakai algoritma KNN dan *Decision Tree*. Berdasarkan percobaan tersebut telah didapatkan bahwa algoritma KNN mendapat hasil akurasi yang lebih baik dibandingkan *Decision Tree* dengan akurasi mencapai 96,8% berbanding 74%. Percobaan tersebut menyimpulkan bahwa sensor *magnetometer* tidak efektif terhadap rekognisi aktivitas manusia[4].

Ankita Jain dan Vivek Kanhangad(2017) menambahkan sinyal *magnitude* yang berasal dari resultan *accelerometer* sehingga menambahkan fitur yang didapat dari *time domain feature* untuk klasifikasi ADL.

Percobaan tersebut menggunakan algoritma KNN dengan parameter $K = 1$ dan *multiclass* SVM. Berdasarkan percobaan tersebut telah didapatkan bahwa dengan menambahkan sinyal *time domain feature* didapatkan akurasi sebesar 84% untuk SVM dan 74% untuk KNN[5].

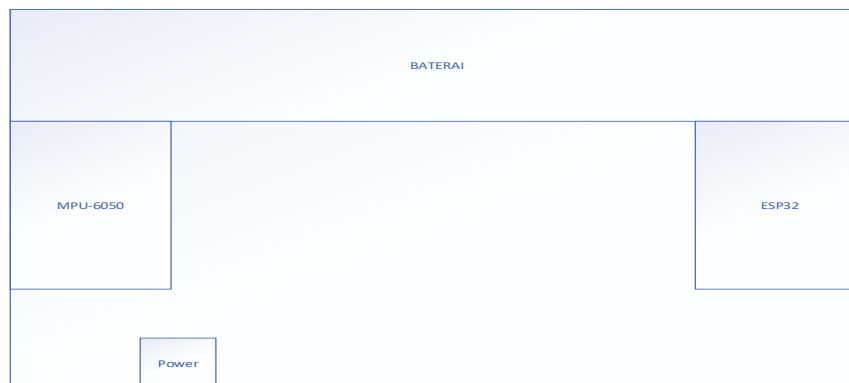
Ines Machado, Ricardo Gomes, Hugo Gamboa, dan Vitor Paixao(2014) menyimpulkan bahwa dengan menggunakan *statistical* dan *time domain feature* pada data dapat membedakan antara aktivitas seseorang dengan baik[10]

3. Sistem yang Dibangun

3.1 Pembuatan Alat

Melakukan pembuatan alat dengan memakai *microcontroller* ESP32 dan MPU-6050 yang mempunyai sensor *accelerometer* dan *gyroscope* untuk mengambil data-data dari sensor tersebut dalam pengujian ADL.


3.1.1 Desain Alat



Gambar 1. Desain Alat

Gambar 1 merupakan rancangan alat dengan menggunakan *microcontroller* ESP32 dan MPU-6050 yang akan dibuat.

3.1.2 Sistem Alat



Gambar 2. Rancangan Sistem Alat

Gambar 2 merupakan rancangan sistem alat, Alat yang digunakan akan mengirimkan data sensor menggunakan MQTT kemudian dari MQTT akan dikirimkan ke dalam server yang telah dibangun.

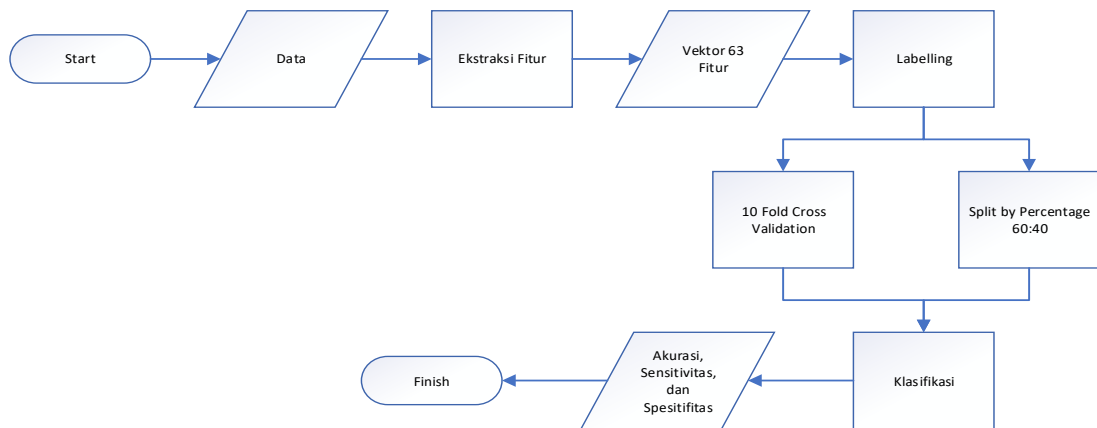
3.2 Pengumpulan Dataset

Melakukan pengujian terhadap 30 orang dewasa sehat yang mempunyai *Body Mass Index* (BMI) yang sama dengan melakukan aktivitas berjalan, berbaring, naik tangga, dan berdiri dengan mengenakan alat yang diletakkan di pinggang selama 5 detik dan menghasilkan data sensor yang terdiri dari *accelerometer axis x,y,z* dan *gyroscope axis x,y,z* pada setiap percobaan ke dalam server menggunakan *Messaging Telemetry Transport* (MQTT). Kemudian dari data 3 *axis accelerometer* tersebut dilakukan perhitungan sehingga didapatkan vektor/magnitude data *accelerometer*. Perhitungan vektor didapat dari persamaan 1 berikut ini:

$$\text{Vektor} = \sqrt{a^2 + b^2 + c^2} \quad (1)$$

3.3 Rancangan Sistem

Sistem yang akan dibangun secara umum merupakan sistem klasifikasi aktivitas manusia berdasarkan data-data dari sensor *accelerometer* dan *gyroscope* menggunakan metode *Support Vector Machine*, *K-Nearest Neighbor*, dan *Naïve Bayes* sebagai klasifikator. Alur sistem yang akan dibuat dapat dilihat dari flowchart berikut:



Gambar 3. Flowchart Sistem

Gambar 3 merupakan proses sistem untuk mengklasifikasi data menggunakan dataset sejumlah 150 data percobaan. Selanjutnya, data sensor tersebut dilakukan ekstraksi fitur dengan *Discrete Wavelet Transform* (DWT) sehingga mereduksi noise yang ada dan menggunakan *time domain feature* sehingga menghasilkan 36 fitur dan diberi label. Data yang ada kemudian dibagi sebagai data *train* dan data *test* dengan menggunakan *10 Fold Cross Validation* dan perbandingan 60:40 sehingga data *train* memiliki 90 data sampel dan data *test* memiliki 60 data sampel. Kemudian dilakukan klasifikasi menggunakan 3 algoritma klasifikasi yaitu SVM *One vs One*, SVM *One vs All*, KNN, dan *Naïve Bayes*. Data yang telah diklasifikasi tersebut akan memunculkan nilai *confusion matrix* yang berisi *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) sehingga didapatkan nilai akurasi tersebut. Perhitungan akurasi, sensitivitas, dan spesitifitas dapat dilihat dari persamaan 2, 3, dan 4 di bawah ini :

$$\text{Akurasi} = \frac{TP+TN}{FP+FN} \times 100\% \quad (2)$$

$$\text{Sensitivitas} = \frac{TP}{(TP+FN)} \times 100\% \quad (3)$$

$$\text{Spesitifitas} = \frac{TN}{(TN+FP)} \times 100\% \quad (4)$$

3.4 Ekstraksi Fitur

Dilakukan *Wavelet Transform* pada data-data setiap axis *accelerometer*, vektor *accelerometer*, dan setiap axis *gyroscope* tersebut sehingga dapat mengurangi *noise* yang terjadi dari sensor tersebut. *Wavelet Transform* pada data tersebut menghasilkan 2 data dari setiap sinyal yaitu *Coefficient Approximation* (CA) yang berisi sinyal yang mempunyai *noise* yang lebih rendah dari sinyal awal dan *Coefficient Detail* (CD) yang berisi sinyal frekuensi tinggi sehingga berisi *noise-noise* dari sinyal awal. Kemudian dilakukan ekstraksi dalam *time-domain feature* sehingga didapatkan 63 fitur yang terdiri dari mean, standar deviasi, max, min, median, kurtosis, skewness, persentil, dan *root mean square*(rms) untuk data vektor *accelerometer*, *accelerometer axis x,y, z* dan *gyroscope axis x,y, z*.

3.5 Klasifikasi

Dilakukan klasifikasi dengan menggunakan 4 algoritma klasifikasi yaitu KNN, 2 SVM (*One vs One* dan *One vs All*), *Naïve Bayes*.

3.5.1 *K-Nearest Neighbor* (KNN)

Metode KNN adalah metode klasifikasi berdasarkan jarak terdekat. Data *train* dipetakan pada k ruang berdimensi banyak lalu diperhitungkan jarak dari data *test* ke data *train* terdekat. Dekat atau jauhnya tetangga dihitung berdasarkan *Euclidean Distance*. Untuk menghitung *Euclidean Distance* digunakan persamaan 5 berikut ini :

$$D(a, b) = \sqrt{\sum_{k=1}^d (a_k - b_k)^2} \quad (5)$$

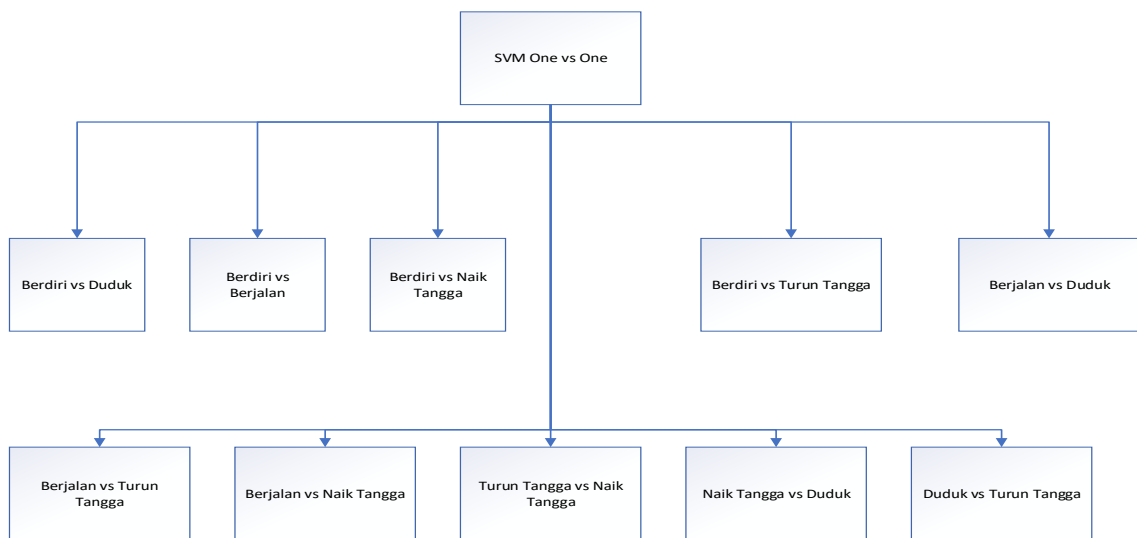
Matriks $D(a,b)$ adalah jarak skalar dari kedua vektor a dan b dari matriks dengan ukuran d dimensi. Jarak dari vektor baru yang ini terhadap seluruh vektor *training sample* dihitung dan

sejumlah k buah yang paling dekat diambil. Titik yang baru, klasifikasinya diprediksikan termasuk pada klasifikasi terbanyak dari titik-titik tersebut.[6]

3.5.2 Multiclass Support Vektor Machine (SVM)

Metode Support Vektor Machine adalah metode yang di desain untuk biner yaitu hanya memiliki 2 kelas. Pada saat pembelajaran, SVM bekerja mencari bidang pemisah terbaik yang memiliki kemampuan generalisasi yang baik. Namun, saat ini SVM dapat mengklasifikasikan data yang memiliki lebih dari dua kelas yang dinamakan *Multiclass Classification*. Terdapat 2 model SVM yang dapat digunakan untuk *Multiclass Classification* tersebut, yaitu SVM Model *One vs One* dan SVM Model *One vs All*. [7]


Pada Model SVM *One vs One* akan dibangun $\frac{k(k-1)}{2}$ buah model. Setiap model klasifikasi dilatih pada data dari dua kelas. Model SVM *One vs One* dapat dilihat seperti pada gambar di bawah ini.



Gambar 4. Model *Multiclass SVM One vs One*

Gambar 4 merupakan model *Multiclass SVM One vs One* yang akan dilakukan untuk mengklasifikasi aktivitas manusia yang mempunyai 5 kelas sehingga mempunyai 10 model *One vs One*.

Pada model SVM *One vs All* akan dibangun model sejumlah k buah model. Setiap model klasifikasi akan dilatih menggunakan keseluruhan data dan dapat dilihat seperti pada gambar dibawah ini.



Gambar 5. Model *Multiclass SVM One vs All*

Gambar 5 merupakan model *Multiclass SVM One vs All* yang akan dilakukan untuk mengklasifikasi aktivitas manusia yang mempunyai 4 kelas sehingga mempunyai 4 model *One vs All* yaitu setiap kelas dan yang bukan termasuk kelas tersebut.

3.5.3 Naïve Bayes

Metode Naïve Bayes adalah Algoritma *Supervised Learning* yang menggunakan metode probabilitas dan statistik. Algoritma Naïve Bayes memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya sehingga dikenal sebagai Teorema Bayes. Ciri utama dari Algoritma Naïve Bayes adalah asumsi yang sangat kuat akan independensi dari masing-masing kejadian. [11]

3.5.3.1 Gaussian Naïve Bayes

Metode Naïve Bayes yang mengasumsikan bahwa fitur-fitur yang ada berbentuk gaussian (distribusi normal) dan menggunakan persamaan 6 berikut ini

$$P(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (6)$$

3.5.3.2 Bernoulli Naïve Bayes

Metode Naïve Bayes yang mengasumsikan bahwa fitur-fitur yang ada berbentuk distribusi Bernoulli dan menggunakan persamaan 7 berikut ini

$$P(x_i | y) = P(i | y)x_i + (1 - P(i | y))(1 - x_i) \quad (7)$$

3.6 K-Fold Cross Validation

K-Fold Cross Validation merupakan Teknik validasi silang untuk mengevaluasi suatu model dimana data dipisah menjadi dua subset yaitu data proses pembelajaran dan data validasi[8]. Model dilatih oleh subset pembelajaran dan divalidasi oleh subset validasi. Biasanya metode ini digunakan karena dapat mengurangi waktu komputasi dengan tetap menjaga keakuratan estimasi. Untuk pemilihan k dapat didasarkan pada ukuran kebutuhan penelitian. Pada umumnya penelitian memilih dan menggunakan k=10 untuk mendapatkan akurasi yang optimal[9].

3.7 Skenario Pengujian

3.7.1 10 Fold Cross Validation

Melakukan pengujian dengan mencari *Tuning* Parameter terbaik dari tiap-tiap algoritma klasifikasi yang digunakan yaitu k pada KNN, kernel pada SVM *One vs One* dan SVM *One vs*

All, dan Naïve Bayes dengan menggunakan 10 *Fold Cross Validation* yang membagi data menjadi 10 bagian dan melakukan pengujian setiap bagian menjadi data *test*.

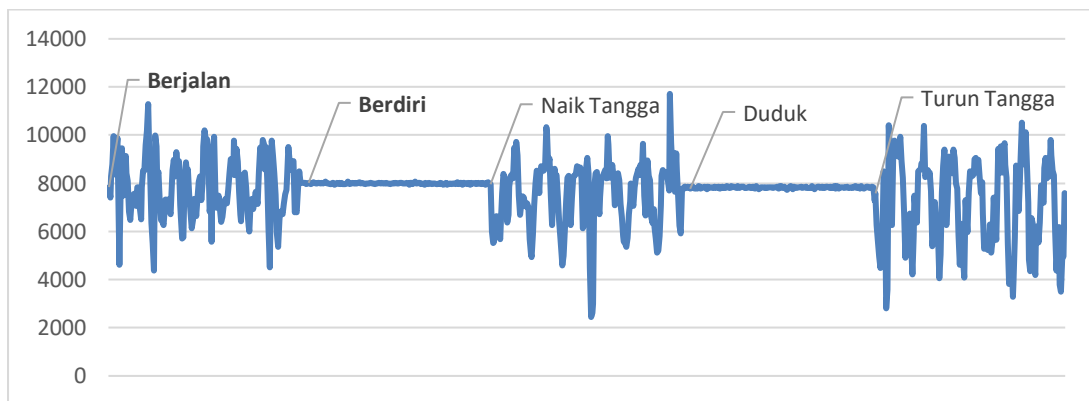
3.7.2 *Split by Percentage 60:40 (Random Sampling)*

Melakukan pengujian dengan mencari *Tuning Parameter* terbaik dari tiap-tiap algoritma klasifikasi yang digunakan yaitu *k* pada KNN, kernel pada SVM *One vs One* dan SVM *One vs All*, dan Naïve Bayes dengan menggunakan *Split by Percentage* yang membagi data menjadi 60% data *train* yaitu dan 40% data *test* sehingga data dengan acak sebanyak 10 kali.


4. Evaluasi

4.1 Dataset


Dataset yang telah dibuat dari 30 subyek (15 Laki – laki dan 15 Perempuan) terdiri dari 7 sinyal yaitu *Accelerometer axis x,y, z*, vektor *accelerometer*, *gyroscope axis x,y*, dan *z*. 7 Sinyal tersebut dapat dilihat pada gambar 6-12 berikut ini.




Gambar 6. Sinyal vektor dari Accelerometer




Gambar 7. Sinyal Accelerometer axis-x



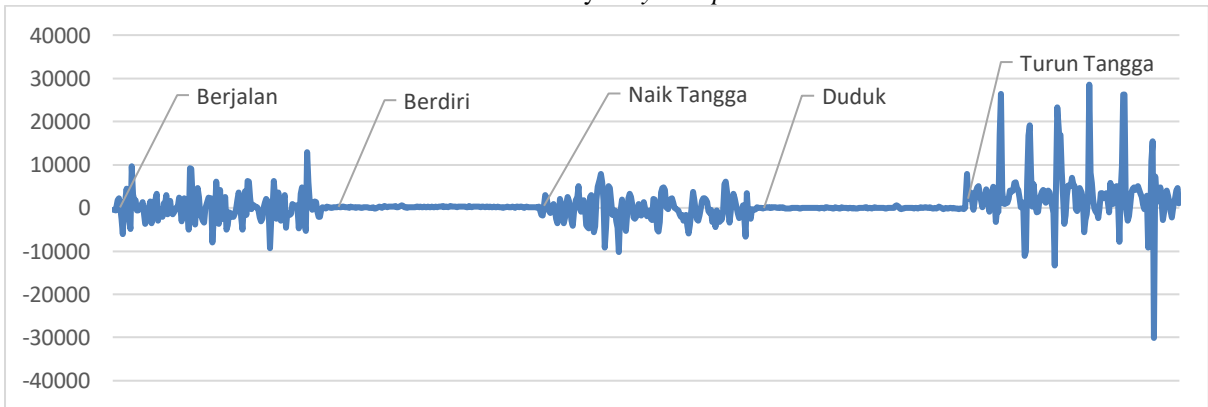
Gambar 8. Sinyal Accelerometer axis-y



Gambar 9. Sinyal Accelerometer axis-z



Gambar 10. Sinyal Gyroscope axis-x



Gambar 11. Sinyal Gyroscope axis-y



Gambar 12. Sinyal Gyroscope axis-z

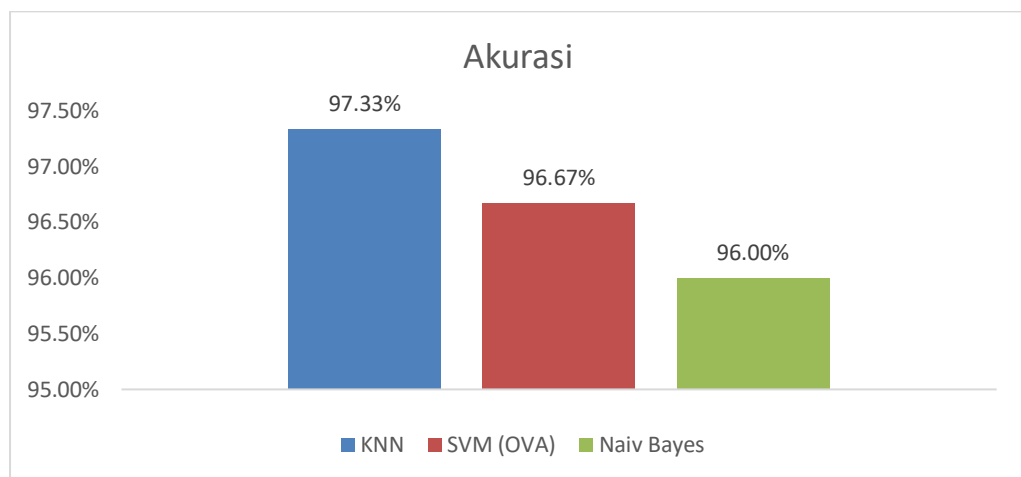
4.2 Hasil Pengujian

4.2.1 Hasil Pengujian 1 (10 Fold Cross Validation)

Pada pengujian algoritma klasifikasi dengan 10 Fold Cross Validation didapatkan algoritma KNN dengan K = 5, algoritma SVM One vs All (OVA) dengan kernel RBF dan algoritma Gaussian Naïve Bayes menghasilkan akurasi terbaik pada masing masing algoritma.

Table 1. Tabel 10 Fold Cross Validation

Kategori	KNN	SVM OVA	Naïve Bayes
Akurasi	97.33%	96.67%	96%
Waktu run	0.00299 s	0.01063 s	0,003191 s



Gambar 13. Akurasi dengan 10 Fold Cross Validation

Dari gambar 5 didapatkan hasil bahwa algoritma KNN dengan K = 5 menghasilkan akurasi yang lebih baik dari algoritma lainnya dengan menggunakan 10 Fold Cross Validation tetapi KNN membutuhkan waktu lebih cepat dengan 0,00339 detik untuk pemrosesan.

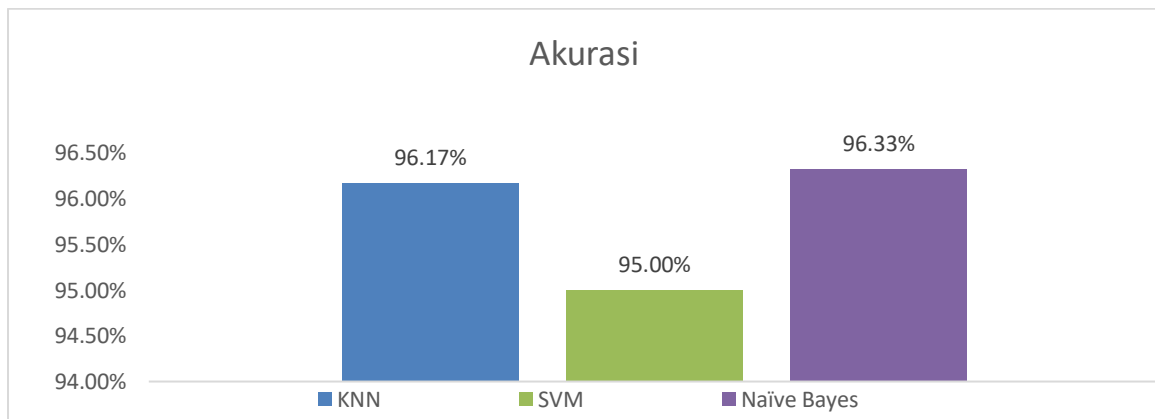
4.2.2 Hasil Pengujian 2 (Split by Percentage 60:40)

Pada pengujian algoritma klasifikasi dengan Split by Percentage 60:40 untuk data train dan data test didapatkan algoritma KNN dengan K = 3, algoritma SVM One vs All (OVA) dengan kernel RBF dan algoritma Gaussian Naïve Bayes menghasilkan akurasi terbaik pada masing masing


algoritma. Pengujian dilakukan sebanyak 10 kali dan memakai rata-rata akurasi dari 10 kali pengujian tersebut.

Table 2. Tabel Hasil Pengujian 2


Kategori	KNN	SVM	Naïve Bayes
Akurasi	96.17%	95%	96.33%
Sensitivitas Berdiri	98.32%	99.38%	100%
Sensitivitas Berjalan	90.43%	92.99%	96%
Sensitivitas Naik Tangga	96.34%	87%	99.23%
Sensitivitas Turun Tangga	96.26%	97.37%	86.93%
Sensitivitas Duduk	100%	97.98%	99.17%
Spesitifitas Berdiri	100%	99.57%	99.78%
Spesitifitas Berjalan	99.53%	98.91%	97.68%
Spesitifitas Naik Tangga	98.74%	98.73%	98.55%
Spesitifitas Turun Tangga	97.21%	96.73%	99.38%
Spesitifitas Duduk	99.58%	98.18%	100%
Waktu	0.00299 s	0.00962 s	0.003290 s



Gambar 14. Grafik Akurasi Hasil Pengujian



Gambar 15. Grafik Sensitivitas per Kelas



Gambar 16. Grafik Spesifitas per Kelas

Berdasarkan Table 2, gambar 14, gambar 15 dan gambar 16 telah didapatkan hasil bahwa algoritma KNN mendapatkan hasil akurasi tertinggi yaitu 97.33% dibanding algoritma lainnya dengan menggunakan *Percentage by Split* 60 : 40 dengan 98.32% sensitivitas berdiri, 90,43% sensitivitas berjalan, 96.34% sensitivitas naik tangga, 96.26% sensitivitas turun tangga dan 100%, sensitivitas duduk dan mendapat 100% spesifitas berdiri, 99.53% spesifitas berjalan, 98.74% spesifitas naik tangga, 97.21% spesifitas turun tangga, dan 99.58% spesifitas duduk dan menghasilkan KNN memiliki waktu terbaik dalam prosesnya.

4.3 Analisis Hasil Pengujian

Setelah dilakukan pengujian dengan 10 *Fold Validation* dan *Split by Percentage* 60:40 dengan *random sampling* telah diperoleh hasil bahwa algoritma KNN mempunyai akurasi tertinggi dengan 97,33% pada 10 *Fold Validation* dan *Naïve Bayes* 96,33% pada *Split by Percentage* sehingga algoritma KNN akan lebih baik jika data *train* yang dimiliki lebih banyak dan *Naïve Bayes* selalu konsisten dikarenakan mempunyai metode yang mengasumsikan setiap fitur tidak mempunyai keterkaitan antar satu sama lain. Oleh karena itu, KNN dapat dikatakan algoritma yang lebih baik dibandingkan algoritma lainnya yang diuji untuk klasifikasi ADL.

Table 3. Confusion Matrix KNN percobaan ke 9

		<i>Predicted Class</i>				
		Berjalan	Berdiri	Turun Tangga	Duduk	Naik Tangga
<i>Actual Class</i>	Berjalan	11	0	1	0	0
	Berdiri	0	9	0	0	0
	Turun Tangga	0	0	13	0	1
	Duduk	0	0	0	18	0
	Naik Tangga	0	0	0	0	7

Tabel 3 merupakan *Confusion Matrix* dari algoritma KNN. Dari tabel tersebut terlihat bahwa ada kelas berjalan yang terklasifikasi sebagai turun tangga dan ada kelas turun tangga terklasifikasi sebagai naik tangga. Hal ini dikarenakan pergerakan antara jalan , turun tangga, dan naik tangga tidak terlalu mempunyai perbedaan yang signifikan, sedangkan berjalan tidak ada yang terdeteksi sebagai berdiri atau duduk dikarenakan memiliki pola pergerakan yang sangat berbeda.

Berdasarkan hasil analisis keseluruhan, masing-masing algoritma klasifikasi yang diuji sudah cukup berhasil untuk mengklasifikasi ADL dengan baik karena mendapatkan akurasi mencapai 95% menggunakan 63 fitur yang didapat.

5. Kesimpulan

Berdasarkan hasil analisis dari seluruh skenario pengujian yang dilakukan dalam penelitian tugas akhir ini, maka diperoleh kesimpulan sebagai berikut:

1. Sistem klasifikasi ADL berdasarkan sensor *accelerometer* dan *gyroscope* telah dibuat dan menghasilkan akurasi rata-rata pada algoritma KNN dengan akurasi mencapai 97.33%, SVM dengan rata-rata akurasi mencapai 95%, dan Naïve Bayes dengan rata-rata akurasi mencapai 96.33%.
2. Algoritma KNN menjadi algoritma terbaik pada klasifikasi ADL dengan dataset yang telah dibuat.

Saran yang dapat diberikan untuk pengembangan penelitian berikutnya adalah :

1. Diharapkan pada penelitian selanjutnya, aktivitas manusia yang direkognisi adalah aktivitas manusia yang menyebabkan bahaya seperti jatuh sehingga sistem menjadi lengkap dikarenakan sudah mempunyai data untuk rekognisi ADL dan jatuh.
2. Melanjutkan penelitian tetapi subyek yang dituju yaitu orang tua sehat.

Daftar Pustaka

- [1] BPS, *Statistik Penduduk Lanjut Usia*. 2015. Jakarta : Penerbit Badan Pusat Statistik.
- [2] M. Jonathan, C. Mohamad, S. Robert. "One Againsts One" or "One Against All": Which One is Better for Handwriting Recognition with SVM?" Guy Lorette. Tenth International Workshop on Frontiers.
- [3] M. Zubair, S. Kibong, Y. Changwoo. "Human Activity Recognition Using Wearable Accelerometer Sensors." in *IEEE International Conference on Consumer Electronics-Asia*. 2016.
- [4] B. Charlene V. San, T. C. Nestor Michael. "Basic Human Activity Recognition Based on Sensor Fusion in Smartphones" in *IEEE IM*. 2017.
- [5] J. Ankita and K. Vivek. "Human Activitiy Classification in Smartphones using Accelerometer and Gyroscope Sensors"
- [6] D. P. Vivencio, E. Hruschka, M. Nicoletti, E. dos Santos, and S. Galvao, "Feature-weighted k-Nearest Neighbor Classifier," *Foundations of Computational Intelligence, 2007. FOCI 2007. IEEE Symposium*, pp. 481–486, 2007.
- [7] K. Sembiring. Penerapan teknik support vector machine untuk pendeteksian intrusi pada jaringan.
- [8] A. Wibowo, "10 FOLD-CROSS VALIDATION," BINUS, 24 November 2017. [Online]. Available: <https://mti.binus.ac.id/2017/11/24/10-fold-cross-validation/>. [Accessed 8 August 2018].
- [9] Z. Nematzadeh , R. Ibrahim and A. Selamat , "Comparative Studies on Breast Cancer," in *IEEE*, Kinabalu, 2015.
- [10] M. Ines, G. Ricardo, G. Hugo, and P. Vitor, "Human Activity Recognition from Triaxial Accelerometer Data" in *Proceedings of the International Conference on Bio-Inspired Systems and Signal Processing*. 2014.pp.155-162
- [11] Z. Harry, "The Optimality of Naïve Bayes"

Lampiran

Table 4. Tabel Akurasi KNN dengan *Percentage by Split*

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	95.00	95.00	95.00	93.33	95.00	95.00	93.33	90.00	93.33	80.00
2	93.33	93.33	93.33	90.00	91.67	93.33	88.33	90.00	88.33	91.67
3	93.33	91.67	93.33	86.67	93.33	93.33	93.33	93.33	93.33	93.33
4	98.33	93.33	91.67	91.67	90.00	90.00	90.00	93.33	90.00	93.33
5	96.67	96.67	96.67	96.67	96.67	95.00	95.00	96.67	96.67	91.67
6	96.67	98.33	100.00	98.33	96.67	98.33	98.33	98.33	98.33	96.67
7	96.67	93.33	98.33	95.00	96.67	83.33	88.33	81.67	81.67	85.00
8	98.33	100.00	100.00	100.00	100.00	98.33	96.67	96.67	98.33	98.33
9	95.00	91.67	96.67	95.00	95.00	95.00	95.00	91.67	95.00	93.33
10	96.67	95.00	96.67	91.67	95.00	90.00	91.67	88.33	90.00	88.33
Rata-rata	96.00	94.83	96.17	93.83	95.00	93.17	93.00	92.00	92.50	91.17

Table 5. Tabel Akurasi KNN dengan *10 Fold Cross Validation*

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	100.00	93.33	100.00	93.33	93.33	93.33	80.00	100.00	100.00	93.33
2	100.00	100.00	93.33	100.00	100.00	100.00	100.00	100.00	93.33	86.67
3	100.00	100.00	93.33	93.33	100.00	93.33	100.00	100.00	100.00	93.33
4	86.67	100.00	93.33	100.00	93.33	93.33	100.00	100.00	93.33	100.00

2	90.91%	90.91%	90.91%	90.91%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
3	92.31%	92.31%	92.31%	92.31%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	91.67%	100.00%	91.67%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
8	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
Rata-rata	98.32%	96.58%	98.32%	97.49%	100.00%	100.00%	100.00%	100.00%	100.00%	97.69%

Table 17. Tabel Spesifitas Turun Tangga dengan KNN

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	95.56%	95.56%	95.56%	91.67%	93.62%	93.62%	91.67%	88.00%	91.67%	83.33%
2	95.56%	93.62%	93.62%	89.80%	90.00%	91.84%	88.00%	89.80%	88.00%	91.67%
3	95.65%	93.62%	95.65%	88.00%	93.75%	92.00%	93.75%	95.65%	93.75%	95.65%
4	100.00%	94.00%	95.74%	93.88%	92.00%	92.00%	93.75%	97.83%	95.65%	100.00%
5	95.92%	95.92%	97.87%	95.92%	95.92%	94.00%	94.00%	95.92%	95.92%	93.75%
6	97.83%	97.87%	100.00%	97.87%	97.83%	97.87%	97.87%	97.87%	97.87%	97.83%
7	97.78%	95.56%	97.83%	95.65%	97.78%	85.71%	89.58%	84.00%	84.00%	87.50%
8	100.00%	100.00%	100.00%	100.00%	100.00%	98.08%	98.04%	98.04%	98.08%	98.08%
9	97.83%	95.65%	97.87%	95.83%	95.83%	95.83%	95.83%	93.75%	95.83%	93.88%
10	97.92%	97.87%	97.92%	93.88%	95.92%	93.75%	93.88%	90.20%	92.00%	91.84%
Rata-rata	97.40%	95.97%	97.21%	94.25%	95.26%	93.47%	93.64%	93.11%	93.28%	93.35%

Table 18. Tabel Sensitivitas Turun Tangga dengan KNN

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	93.33%	100.00%	93.33%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	92.86%	100.00%	100.00%	100.00%	100.00%	100.00%	90.00%	100.00%	100.00%	91.67%
3	92.31%	100.00%	92.31%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	92.31%	90.00%	76.92%	81.82%	80.00%	88.89%	75.00%	78.57%	71.43%	75.00%
5	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	90.91%
6	92.86%	100.00%	100.00%	100.00%	92.86%	100.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	100.00%	93.33%	80.00%	90.91%	77.78%	77.78%	81.82%
8	90.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	92.31%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
Rata-rata	94.60%	99.00%	96.26%	98.18%	96.62%	96.89%	95.59%	95.63%	94.92%	93.94%

Table 19. Tabel Spesifitas Naik Tangga dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	95.92%	98.00%	90.70%	95.92%	98.00%	97.96%
2	97.67%	93.33%	88.89%	95.45%	97.73%	97.37%
3	97.96%	97.92%	95.12%	97.96%	97.92%	97.83%
4	100.00%	100.00%	92.11%	100.00%	100.00%	100.00%
5	97.92%	97.92%	94.87%	97.96%	97.96%	97.83%
6	100.00%	100.00%	94.87%	100.00%	100.00%	100.00%
7	96.08%	97.83%	97.44%	96.00%	97.87%	97.83%

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
8	98.00%	97.92%	92.31%	98.00%	97.87%	97.92%
9	97.92%	97.92%	94.59%	100.00%	100.00%	97.87%
10	100.00%	97.78%	94.74%	100.00%	100.00%	100.00%
Rata-rata	98.15%	97.86%	93.56%	98.13%	98.73%	98.46%

Table 20. Tabel Sensitivitas Naik Tangga dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	90.00%	100.00%	100.00%	81.82%	100.00%	90.91%
2	93.33%	100.00%	100.00%	100.00%	100.00%	87.50%
3	100.00%	83.33%	100.00%	100.00%	83.33%	71.43%
4	93.33%	100.00%	100.00%	100.00%	100.00%	87.50%
5	81.82%	90.00%	88.89%	90.00%	90.00%	75.00%
6	87.50%	93.33%	92.31%	93.33%	87.50%	87.50%
7	77.78%	80.00%	88.89%	87.50%	72.73%	80.00%
8	75.00%	50.00%	80.00%	75.00%	50.00%	54.55%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	81.25%	100.00%	100.00%	68.42%	86.67%	76.47%
Rata-rata	88.00%	89.67%	95.01%	89.61%	87.02%	81.09%

Table 21. Tabel Spesitifitas Duduk dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
8	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	81.82%	100.00%	100.00%	81.82%	100.00%
Rata-rata	100.00%	98.18%	100.00%	100.00%	98.18%	100.00%

Table 22. Tabel Sensitivitas Duduk dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
6	100.00%	88.89%	100.00%	100.00%	88.89%	100.00%
7	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
8	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	90.91%	100.00%	100.00%	90.91%	100.00%
Rata-rata	100.00%	97.98%	100.00%	100.00%	97.98%	100.00%

Table 23. Tabel Spesitifitas Berjalan dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	96.08%	95.92%	100.00%	96.00%	98.00%	100.00%
3	97.92%	97.87%	100.00%	97.92%	97.87%	95.74%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	97.83%	97.83%	100.00%	100.00%	97.87%	97.73%
6	98.00%	98.00%	100.00%	98.00%	98.00%	97.96%
7	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
8	95.35%	97.44%	72.22%	95.35%	97.37%	91.11%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	97.83%	97.78%	100.00%	97.67%	100.00%	97.78%
Rata-rata	98.30%	98.48%	97.22%	98.49%	98.91%	98.03%

Table 24. Tabel Sensitivitas Berjalan dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	86.67%	92.86%	48.15%	92.86%	92.86%	92.86%
2	87.50%	70.00%	34.62%	87.50%	80.00%	56.25%
3	100.00%	100.00%	50.00%	100.00%	91.67%	90.91%
4	100.00%	100.00%	39.13%	100.00%	100.00%	90.00%
5	100.00%	91.67%	46.15%	92.31%	91.67%	78.57%
6	100.00%	100.00%	50.00%	90.00%	100.00%	90.00%
7	80.00%	72.73%	38.10%	72.73%	80.00%	61.54%
8	93.33%	100.00%	100.00%	93.33%	93.75%	100.00%
9	100.00%	100.00%	45.83%	100.00%	100.00%	91.67%
10	100.00%	100.00%	50.00%	100.00%	100.00%	100.00%
Rata-rata	94.75%	92.73%	50.20%	92.87%	92.99%	85.18%

Table 25. Tabel Spesitifitas Berdiri dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
8	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	95.74%	100.00%	95.56%	95.74%	100.00%
Rata-rata	100.00%	99.57%	100.00%	99.56%	99.57%	100.00%

Table 26. Tabel Sensitivitas Berdiri dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	100.00%	91.67%	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	88.24%	100.00%	100.00%	93.75%	100.00%
8	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
10	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
Rata-rata	100.00%	97.99%	100.00%	100.00%	99.38%	100.00%

Table 27. Tabel Spesitifitas Turun Tangga dengan SVM

No.	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	95.92%	100.00%	83.02%	95.92%	100.00%	97.96%
2	97.73%	97.62%	76.36%	97.67%	97.78%	84.91%
3	100.00%	97.87%	83.33%	100.00%	97.87%	95.74%
4	98.00%	100.00%	83.02%	100.00%	100.00%	94.23%
5	95.56%	97.67%	76.79%	95.65%	97.73%	91.49%
6	98.00%	98.00%	84.21%	98.00%	98.00%	96.08%
7	95.74%	91.67%	78.95%	93.75%	91.84%	88.46%
8	95.65%	90.00%	96.55%	95.65%	88.24%	95.45%
9	100.00%	100.00%	80.70%	100.00%	100.00%	97.96%
10	95.92%	100.00%	80.70%	95.65%	95.83%	94.00%
Rata-rata	97.25%	97.28%	82.36%	97.23%	96.73%	93.63%

Table 28. Tabel Sensitivitas Turun Tangga dengan SVM

No	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	90.00%	100.00%	100.00%	90.00%	100.00%	100.00%
2	86.67%	81.25%	100.00%	76.47%	92.86%	100.00%
3	85.71%	91.67%	100.00%	85.71%	100.00%	100.00%
4	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%
5	86.67%	93.33%	100.00%	92.86%	93.33%	100.00%
6	100.00%	90.00%	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	90.91%	100.00%	100.00%

No	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
8	84.62%	88.89%	38.71%	84.62%	87.50%	84.62%
9	91.67%	91.67%	0.00%	100.00%	100.00%	90.91%
10	100.00%	85.71%	100.00%	100.00%	100.00%	100.00%
Rata-rata	92.53%	92.25%	83.87%	92.06%	97.37%	97.55%

Table 29. Spesitifitas dan Sensitivitas Turun Tangga pada Naïve Bayes

No	Spesitifitas Turun Tangga		Sensitivitas Turun Tangga	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	97.87%	98.00%	66.67%	80.00%
2	95.56%	100.00%	66.67%	66.67%
3	97.78%	100.00%	83.33%	78.57%
4	97.83%	100.00%	75.00%	90.91%
5	93.62%	97.92%	75.00%	91.67%
6	95.35%	100.00%	75.00%	87.50%
7	100.00%	100.00%	81.25%	100.00%
8	95.45%	100.00%	62.50%	92.31%
9	93.88%	97.92%	81.82%	91.67%
10	94.12%	100.00%	66.67%	90.00%
Rata-rata	96.14%	99.38%	73.39%	86.93%

Table 30. Spesitifitas dan Sensitivitas Naik Tangga pada Naïve Bayes

No	Spesitifitas Naik Tangga		Sensitivitas Naik Tangga	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	100.00%	97.83%	92.86%	100.00%
2	100.00%	98.00%	58.33%	100.00%
3	95.65%	95.92%	83.33%	100.00%
4	95.35%	100.00%	86.67%	100.00%
5	95.24%	100.00%	86.67%	100.00%
6	95.92%	98.08%	85.71%	100.00%
7	97.92%	100.00%	90.00%	100.00%
8	97.62%	100.00%	91.67%	92.31%
9	100.00%	97.83%	100.00%	100.00%
10	97.62%	97.87%	92.86%	100.00%
Rata-rata	97.53%	98.55%	86.81%	99.23%

Table 31. Spesitifitas dan Sensitivitas Duduk pada Naïve Bayes

No	Spesitifitas Duduk		Sensitivitas Duduk	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%
4	100.00%	100.00%	100.00%	91.67%
5	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	100.00%
8	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%
10	100.00%	100.00%	100.00%	100.00%
Rata-rata	100.00%	100.00%	100.00%	99.17%

No	Spesitifitas Duduk		Sensitivitas Duduk	
	Bernoulli	Gaussian	Bernoulli	Gaussian
rata				

Table 32. Spesitifitas dan Sensitivitas Berjalan pada Naïve Bayes

No	Spesitifitas Berjalan		Sensitivitas Berjalan	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	90.38%	97.87%	87.50%	91.67%
2	85.42%	91.30%	100.00%	100.00%
3	93.33%	97.73%	85.71%	100.00%
4	94.00%	98.00%	87.50%	100.00%
5	96.23%	98.21%	50.00%	75.00%
6	93.18%	97.78%	85.71%	100.00%
7	93.48%	100.00%	100.00%	100.00%
8	89.80%	95.92%	88.89%	100.00%
9	95.56%	100.00%	80.00%	93.33%
10	95.65%	100.00%	83.33%	100.00%
Rata-rata	92.70%	97.68%	84.87%	96.00%

Table 33. Sensitivitas dan Spesitifitas Berdiri pada Naïve Bayes

No	Spesitifitas Berdiri		Sensitivitas Berdiri	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	100.00%	100.00%	100.00%	100.00%
2	100.00%	100.00%	100.00%	100.00%
3	100.00%	100.00%	100.00%	100.00%
4	100.00%	97.83%	100.00%	100.00%
5	100.00%	100.00%	100.00%	100.00%
6	100.00%	100.00%	100.00%	100.00%
7	100.00%	100.00%	100.00%	100.00%
8	100.00%	100.00%	100.00%	100.00%
9	100.00%	100.00%	100.00%	100.00%
10	100.00%	100.00%	100.00%	100.00%
Rata-rata	100.00%	99.78%	100.00%	100.00%

Table 34. Durasi Klasifikasi Data pada KNN (*Split by Percentage*)

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	0.00203	0.00299	0.00299	0.00299	0.00303	0.00296	0.00303	0.00200	0.00299	0.00299
2	0.00200	0.00200	0.00200	0.00199	0.00300	0.00299	0.00299	0.00399	0.00399	0.00399
3	0.00299	0.00296	0.00299	0.00299	0.00399	0.00299	0.00299	0.00399	0.00299	0.00299
4	0.00299	0.00299	0.00299	0.00200	0.00299	0.00299	0.00299	0.00199	0.00299	0.00299
5	0.00299	0.00299	0.00199	0.00299	0.00299	0.00299	0.00199	0.00299	0.00299	0.00299
6	0.00299	0.00199	0.00299	0.00303	0.00299	0.00296	0.00303	0.00299	0.00299	0.00202
7	0.00299	0.00196	0.00204	0.00199	0.00200	0.00399	0.00303	0.00295	0.00203	0.00200
8	0.00295	0.00303	0.00199	0.00200	0.00303	0.00295	0.00303	0.00200	0.00298	0.00299
9	0.00302	0.00299	0.00297	0.00300	0.00301	0.00299	0.00303	0.00199	0.00298	0.00201
10	0.00299	0.00299	0.00203	0.00200	0.00296	0.00303	0.00200	0.00299	0.00203	0.00297
Rata-rata	0.00280	0.00269	0.00250	0.00250	0.00300	0.00308	0.00281	0.00279	0.00290	0.00279

Table 35. Durasi Klasifikasi Data pada KNN (*10 Fold Cross Validation*)

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
1	0.00300	0.00299	0.00300	0.00299	0.00396	0.00396	0.00302	0.00399	0.00399	0.00401

No.	K = 1	K = 2	K = 3	K = 4	K = 5	K = 6	K = 7	K = 8	K = 9	K = 10
2	0.00299	0.00299	0.00298	0.00299	0.00303	0.00303	0.00299	0.00299	0.00299	0.00398
3	0.00298	0.00299	0.00299	0.00296	0.00298	0.00299	0.00296	0.00299	0.00399	0.00300
4	0.00300	0.00299	0.00299	0.00303	0.00299	0.00295	0.00303	0.00299	0.00399	0.00299
5	0.00300	0.00299	0.00299	0.00299	0.00300	0.00303	0.00299	0.00400	0.00299	0.00398
6	0.00299	0.00300	0.00299	0.00399	0.00200	0.00300	0.00396	0.00298	0.00600	0.00400
7	0.00299	0.00298	0.00300	0.00299	0.00298	0.00395	0.00299	0.00399	0.00297	0.00299
8	0.00595	0.00299	0.00300	0.00299	0.00298	0.00399	0.00399	0.00299	0.00299	0.00399
9	0.00301	0.00297	0.00298	0.00299	0.00301	0.00200	0.00299	0.00399	0.00299	0.00300
10	0.00299	0.00302	0.00300	0.00299	0.00300	0.00299	0.00399	0.00299	0.00301	0.00395
Rata-rata	0.00329	0.00299	0.00299	0.00309	0.00299	0.00319	0.00329	0.00339	0.00359	0.00359

Table 36. Durasi Klasifikasi Data pada SVM (Split by Percentage)

No	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	0.00195	0.00396	0.00198	0.00803	0.00901	0.00893
2	0.00299	0.00299	0.00300	0.00794	0.00947	0.00997
3	0.00199	0.00295	0.00201	0.00698	0.01093	0.00801
4	0.00199	0.00295	0.00304	0.00894	0.00901	0.00798
5	0.00199	0.00204	0.00299	0.00997	0.00898	0.00897
6	0.00199	0.00299	0.00301	0.00798	0.00997	0.00897
7	0.00395	0.00400	0.00299	0.00797	0.01193	0.00901
8	0.00200	0.00332	0.00302	0.00799	0.00994	0.00902
9	0.00399	0.00299	0.00303	0.00896	0.00798	0.00798
10	0.00199	0.00299	0.00199	0.01097	0.00898	0.00894
Rata-rata	0.00248	0.00312	0.00271	0.00857	0.00962	0.00878

Table 37. Durasi Klasifikasi Data pada SVM (10 Fold Cross Validation)

No	One vs One			One vs All		
	Linear	Rbf	Poly	Linear	Rbf	Poly
1	0.00299	0.00399	0.00299	0.01001	0.00958	0.01101
2	0.00199	0.00399	0.00299	0.01197	0.01098	0.01297
3	0.00199	0.00299	0.00299	0.00894	0.01096	0.00997
4	0.00299	0.00299	0.00399	0.00702	0.00998	0.00897
5	0.00300	0.00399	0.00303	0.00794	0.01097	0.01193
6	0.00299	0.00499	0.00398	0.00998	0.01197	0.00997
7	0.00299	0.00499	0.00200	0.00801	0.00998	0.00997
8	0.00299	0.00399	0.00299	0.00898	0.00997	0.01297
9	0.00199	0.00299	0.00354	0.01194	0.01197	0.01002
10	0.00299	0.00399	0.00299	0.00801	0.00993	0.01097
Rata-rata	0.00269	0.00389	0.00315	0.00928	0.01063	0.01087

Table 38. Durasi Klasifikasi Data pada Naïve Bayes

No	Split by Percentage		10 Fold Cross Validation	
	Bernoulli	Gaussian	Bernoulli	Gaussian
1	0.002992	0.002992	0.000000	0.002991

No	<i>Split by Percentage</i>		<i>10 Fold Cross Validation</i>	
2	0.001994	0.004986	0.003985	0.003990
3	0.005984	0.003991	0.002993	0.002992
4	0.002992	0.002993	0.002992	0.002992
5	0.003988	0.002992	0.001995	0.002995
6	0.002992	0.002993	0.002993	0.003986
7	0.005002	0.002977	0.002991	0.002992
8	0.002992	0.002991	0.002993	0.001994
9	0.002993	0.002992	0.003222	0.003990
10	0.002991	0.002992	0.002995	0.002991
Rata-rata	0.003492	0.003290	0.002716	0.003191