



TUGAS AKHIR (AE43250)


**IMPLEMENTASI METODE LSTM PADA *WELDING GLOVE*
BERBASIS SENSOR IMU UNTUK PENGENALAN POSISI
PENGELASAN**

Chika Bintang Yudina Rahmania
NRP. 0922040055

Dosen Pembimbing

1. Aulia Rahma Annisa, S.ST., M.T.
2. Mohammad Basuki Rahmat, S.T., M.T.

PROGRAM STUDI D4 TEKNIK OTOMASI
JURUSAN TEKNIK KELISTRIKAN KAPAL
POLITEKNIK PERKAPALAN NEGERI SURABAYA
SURABAYA
2026



TUGAS AKHIR (AE43250)

**IMPLEMENTASI METODE LSTM PADA *WELDING GLOVE*
BERBASIS SENSOR IMU UNTUK PENGENALAN POSISI
PENGELASAN**

Chika Bintang Yudina Rahmania
NRP. 0922040055

Dosen Pembimbing

- 1. Aulia Rahma Annisa, S.ST., M.T.**
- 2. Mohammad Basuki Rahmat, S.T., M.T.**

**PROGRAM STUDI D4 TEKNIK OTOMASI
JURUSAN TEKNIK KELISTRIKAN KAPAL
POLITEKNIK PERKAPALAN NEGERI SURABAYA
SURABAYA
2026**

(Halaman ini sengaja dikosongkan)

LEMBAR PENGESAHAN

TUGAS AKHIR

IMPLEMENTASI METODE LSTM PADA *WELDING GLOVE* BERBASIS SENSOR IMU UNTUK PENGENALAN POSISI PENGELASAN

Disusun Oleh :

Chika Bintang Yudina Rahmania
0922040055

Diajukan Untuk Memenuhi Salah Satu Syarat Kelulusan
Program Studi D4 Teknik Otomasi
Jurusan Teknik Kelistrikan Kapal

POLITEKNIK PERKAPALAN NEGERI SURABAYA

Disetujui oleh Tim penguji Tugas Akhir Tanggal Ujian : 27 Juli 2026
Periode Wisuda : Oktober 2026

Menyetujui,

Dosen Penguji

1. Noorman Rinanto, S.T., M.T., Ph.D.
2. Aulia Rahma Annisa, S.ST., M.T.
3. Hendro Agus Widodo, S.ST., M.T.
4. Sholahuddin Muhammad Irsyad, S.Tr.T., M.Tr.T.

NIDN/NUPTK

(0014107607)

(0303069102)

(0013076902)

(0337772673130343)

Tanda Tangan

(.....)

(.....)

(.....)

(.....)

Dosen Pembimbing

1. Aulia Rahma Annisa, S.ST., M.T.
2. Mohammad Basuki Rahmat, S.T., M.T.

NIDN/NUPTK

(0303069102)

(0022057304)

Tanda Tangan

(.....)

(.....)

Menyetujui
Ketua Jurusan,



Isa Rachman, S.T., M.T.
NIP.198008162008121001

Mengetahui
Koordinator Program Studi,

Agus Khumaidi, S.ST., M.T.
NIP.199308172020121004

(Halaman ini sengaja dikosongkan)

 PPNS	PERNYATAAN BEBAS PLAGIAT	No. : F.WD I. 021 Date : 3 Nopember 2015 Rev. : 01 Page : 1 dari 1
---	--	--

Yang bertandatangan dibawah ini :

Nama : Chika Bintang Yudina Rahmania

NRP. : 0922040055

Jurusan/Prodi : Teknik Kelistrikan Kapal/D4 Teknik Otomasi

Dengan ini menyatakan dengan sesungguhnya bahwa :

Tugas Akhir yang akan saya kerjakan dengan judul :

**IMPLEMENTASI METODE LSTM PADA *WELDING GLOVE* BERBASIS
SENSOR IMU UNTUK PENGENALAN POSISI PENGELASAN**

Adalah **benar karya saya sendiri** dan **bukan plagiat** dari karya orang lain.

Apabila dikemudian hari terbukti terdapat plagiat dalam karya ilmiah tersebut,
maka saya bersedia menerima **sanksi** sesuai ketentuan peraturan yang berlaku.

Demikian surat pernyataan ini saya buat dengan penuh tanggung jawab.

Surabaya, 19 Agustus 2026

Yang membuat pernyataan,



Chika Bintang Yudina Rahmania
NRP. 0922040055

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Alhamdulillah *robbil alamin*, segala Puji dan rasa syukur Penulis panjatkan ke hadirat Allah SWT atas segala rahmat dan karunia-Nya sehingga Penulis mampu menyelesaikan Tugas Akhir dengan judul **"IMPLEMENTASI METODE LSTM PADA WELDING GLOVE BERBASIS SENSOR IMU UNTUK PENGENALAN POSISI PENGELASAN"** sebagai salah satu syarat dalam penyelesaian pendidikan Diploma 4 (D4) Program Studi Teknik Politeknik Perkapalan Negeri Surabaya

Penulis menyadari bahwa penyelesaian laporan ini tidak lepas dari dukungan, bantuan, dan bimbingan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih setulus-tulusnya kepada:

1. Allah SWT yang telah memberikan kesehatan, kekuatan, kemudahan, serta pertolongan kepada Penulis sehingga dapat melalui proses perkuliahan dan menyelesaikan Tugas Akhir ini. Semoga ilmu yang diperoleh dapat memberikan manfaat dan menjadi bekal bagi Penulis untuk menjadi pribadi yang lebih baik.
2. Orang tua tercinta, Bapak Wahidin Ibu Jumaidah yang selalu memberikan doa, kasih sayang, perhatian, dukungan, serta pengorbanan yang tidak ternilai selama Penulis menempuh pendidikan. Terima kasih atas segala hal yang menyertai setiap langkah Penulis hingga sampai di tahap ini.
3. Para Tante dan Om tersayang, Tante Umi, Tante Nur, Tante Ika, Om Arif, Om Arkhi dan Om han. Terima kasih atas segala perhatian, doa, dukungan dan kebaikan yang telah dicurahkan untuk Penulis pada proses pengerjaan Tugas Akhir ini.
4. Adik laki-laki, Muhammad Tito M.R yang mungkin tidak menyadari betapa berarti kehadirannya. Terimakasih telah membawa canda dan tawa di tengah berbagai proses yang Penulis lalui.
5. Bapak Rachmad Tri Soelistijono, S.T., M.T., selaku Direktur Politeknik Perkapalan Negeri Surabaya.
6. Bapak Isa Rachman, S.T., M.T., selaku Ketua Jurusan Teknik Kelistrikan Kapal.

7. Bapak Agus Khumaidi, S.ST., M.T., selaku Ketua Program Studi D4 Teknik Otomasi.
8. Ibu Aulia Rahma Annisa, S.ST., M.T. selaku Dosen Pembimbing I atas bimbingan, koreksi, dan motivasi dalam penyelesaian Tugas Akhir ini.
9. Bapak Mohammad Basuki Rahmat, S.T., M.T., selaku Dosen Pembimbing II atas bimbingan, koreksi, dan motivasi dalam penyelesaian Tugas Akhir ini.
10. Seluruh Dosen dan Staf Pengajar Jurusan Teknik Kelistrikan Kapal PPNS, atas ilmu dan bimbingan selama masa perkuliahan.
11. Ciwi-ciwi Kelas C, Tsamarah, Rahma dan Della yang telah menjadi bagian dari keseharian Penulis selama menempuh empat tahun masa perkuliahan. Terimakasih untuk tawa yang dibagikan, cerita yang didengarkan dan kebersamaan yang mungkin terlihat sederhana, tetapi selalu memiliki tempat tersendiri dalam ingatan Penulis.
12. Sahabat-sahabat terbaik Penulis, Ariba, Dela dan Edo, yang selalu hadir dalam berbagai cerita, tawa, dan keluh kesah yang mewarnai hari-hari Penulis. Terima kasih telah menjadi tempat untuk berbagi cerita, menjadi pengingat ketika Penulis kehilangan arah dan tetap hadir dalam suka maupun duka.
13. Rekan-rekan Teknik Otomasi Angkatan 2022, khususnya kelas C (OtomaCi) atas kebersamaan dan kenangan berharga selama empat tahun menempuh studi.
14. Semua pihak yang tidak dapat Penulis sebutkan satu persatu. Terimakasih atas segala bentuk bantuan serta motivasi yang diberikan bagi Penulis.

Semoga Allah SWT membalas seluruh kebaikan pihak-pihak yang telah membantu. Penulis menyadari bahwa laporan ini masih memiliki kekurangan, sehingga kritik dan saran yang membangun sangat diharapkan. Semoga karya ini dapat memberikan manfaat bagi perkembangan ilmu pengetahuan dan teknologi.

Surabaya, 19 Agustus 2026



Penulis

IMPLEMENTASI METODE LSTM PADA *WELDING GLOVE* BERBASIS SENSOR IMU UNTUK PENGENALAN POSISI PENGELASAN

Chika Bintang Yudina Rahmania

ABSTRAK

Penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem *wearable* berbasis multi-sensor *Inertial Measurement Unit* (IMU) untuk klasifikasi otomatis posisi pengelasan menggunakan metode *Long Short-Term Memory* (LSTM). Sistem yang dikembangkan mampu mengenali empat posisi pengelasan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*) berdasarkan pola pergerakan tangan *welder* selama proses pengelasan berlangsung. Akuisisi data dilakukan menggunakan sensor IMU ICM-20948 yang terintegrasi dengan perangkat *wearable* berbasis ESP32. Data *accelerometer*, *gyroscope*, dan *magnetometer* yang diperoleh kemudian melalui tahapan *preprocessing* yang meliputi *filtering*, normalisasi, dan segmentasi (*windowing*) sebelum digunakan sebagai masukan bagi model LSTM. Model LSTM yang telah dilatih berhasil mengklasifikasikan posisi pengelasan berdasarkan data *time-series* pergerakan tangan dan diintegrasikan dengan sistem monitoring secara *real-time*. Data sensor dikirimkan ke *backend* Python menggunakan protokol HTTP untuk diproses, disimpan ke dalam basis data, serta ditampilkan pada dashboard berbasis web. Dashboard menyediakan visualisasi hasil klasifikasi secara *real-time*, riwayat aktivitas, grafik aktivitas, serta informasi performa klasifikasi sehingga memudahkan proses pemantauan aktivitas pengelasan secara berkelanjutan. Berdasarkan hasil pengujian, model LSTM memperoleh *accuracy* sebesar 96%, dengan *macro average precision* sebesar 98%, *macro average recall* sebesar 95%, dan *macro average F1-score* sebesar 96%. Selain itu, pada pengujian sistem secara *real-time*, diperoleh nilai *confidence* rata-rata sebesar 91,41% pada posisi 1G, 90,27% pada posisi 2G, 91,09% pada posisi 3G, dan 95,04% pada posisi 4G, serta rata-rata *latency* sebesar 33,33 ms (0,033 detik). Hasil penelitian menunjukkan bahwa sistem yang dikembangkan mampu melakukan klasifikasi posisi pengelasan dan monitoring aktivitas secara *real-time*, sehingga dapat mendukung evaluasi aktivitas *welder* secara lebih objektif serta menjadi salah satu penerapan teknologi sensor dan kecerdasan buatan pada industri maritim dan perkapalan.

Kata kunci: Klasifikasi Posisi Pengelasan, *Multi-Sensor* IMU, *Wearable System*, Metode LSTM, *Human Activity Recognition*.

(Halaman ini sengaja dikosongkan)

IMPLEMENTATION OF LSTM METHOD ON AN IMU SENSOR-BASED WELDING GLOVE FOR WELDING POSITION RECOGNITION

Chika Bintang Yudina Rahmania

ABSTRACT

This study aimed to design and implement a wearable system based on a multi-sensor Inertial Measurement Unit (IMU) to automatically classify welding positions using the Long Short-Term Memory (LSTM) method. The proposed system was designed to recognize four welding positions, namely 1G (flat), 2G (horizontal), 3G (vertical), and 4G (overhead), based on the welder's hand movement patterns during the welding process. Data acquisition was performed using an ICM-20948 IMU sensor integrated with an ESP32-based wearable device. The collected accelerometer, gyroscope, and magnetometer data underwent preprocessing, including filtering, normalization, and windowing, before being used as input for the LSTM model. The trained LSTM model successfully classified welding positions from time-series hand-movement data and was integrated into a real-time monitoring system. Sensor data were transmitted to a Python backend via the HTTP protocol for processing, stored in a database, and displayed on a web-based monitoring dashboard. The dashboard provides real-time visualization of classification results, activity history, activity graphs, and classification performance, enabling continuous monitoring of welding activities. Experimental results showed that the proposed LSTM model achieved an accuracy of 96%, with a macro-average precision of 98%, a macro-average recall of 95%, and a macro-average F1-score of 96%. Furthermore, the real-time system achieved an average confidence score of 91.41% for the 1G position, 90.27% for 2G, 91.09% for 3G, and 95.04% for 4G, with an average latency of 33.33 ms (0.033 s). These results demonstrate that the proposed system can accurately classify welding positions and perform real-time monitoring, providing a practical solution for objective welder activity evaluation and supporting the application of sensor technology and artificial intelligence in the maritime and shipbuilding industries.

Keywords: *Welder Position Classification, Multi-Sensor IMU, Wearable System, LSTM Method, Human Activity Recognition.*

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

TUGAS AKHIR	i
LEMBAR PENGESAHAN	iii
PERNYATAAN BEBAS PLAGIAT	v
KATA PENGANTAR.....	vii
ABSTRAK	ix
<i>ABSTRACT</i>	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL	xvii
DAFTAR GAMBAR.....	xix
DAFTAR NOTASI.....	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Penelitian	5
1.4 Tujuan Penelitian.....	6
1.5 Manfaat Penelitian.....	6
BAB 2 TINJAUAN PUSTAKA.....	7
2.1 Kajian Penelitian Terdahulu	7
2.2 Kajian Pustaka	9
2.2.1 Pengelasan pada Konstruksi Kapal.....	9
2.2.2 Posisi Pengelasan (<i>Welding Position</i>).....	9
2.2.3 <i>Inertial Measurement Unit</i> (IMU)	11
2.2.4 <i>Human Activity Reccognition</i> (HAR)	12
2.2.5 <i>Deep Learning</i> untuk Data <i>Time-Series</i>	13
2.2.6 Metode <i>Long Short-Term Memory</i> (LSTM).....	13
2.3 Hardware dan Software yang Digunakan.....	15
2.3.1 ESP32 Microcontroller	15
2.3.2 ICM-20948.....	17
2.3.3 Li-Po 3.7V 5000mAh	18
2.3.4 <i>Module Charger</i>	18

2.3.5 CaldWell <i>Glove</i>	19
2.3.6 SD <i>Card</i> dan	20
2.3.7 Arduino IDE	21
2.3.8 VS Code	22
2.3.9 Python	23
2.3.10 HTTP	25
BAB 3 METODE PENELITIAN	27
3.1 Konsep Penelitian	27
3.1.1 Diagram Blok Sistem	27
3.1.2 Diagram Cara Kerja Sistem Software	29
3.1.3 Flowchart Alur Kerja Sistem	30
3.1.4 Diagram Aliran Data Proses	32
3.2 Tahapan Penelitian	33
3.2.1 Identifikasi Masalah	34
3.2.2 Penetapan Tujuan dan Manfaat Penelitian	35
3.2.3 Studi Literatur	35
3.2.4 Analisis Kebutuhan Sistem	36
3.3 Desain dan Perancangan Sistem	37
3.3.1 <i>Hardware Electric</i>	37
3.3.2 <i>Hardware Mekanik</i>	38
3.3.3 Perancangan Desain UI/UX	39
3.3.4 Perancangan Metode LSTM	42
3.4 Skema Pengumpulan Data	44
3.4.1 Objek dan Perangkat Pengumpulan Data	45
3.4.2 Jenis dan Jumlah Data yang Dikumpulkan	45
3.4.3 Skenario dan Durasi Pengambilan Data	46
3.4.4 Periode Pengambilan Data	47
3.5 Skema Pengujian	48
BAB 4 HASIL DAN PEMBAHASAN	49
4.1 Perancangan <i>Hardware</i>	49
4.1.1 Perancangan <i>Hardware</i> Mikrokontroler ESP32	49
4.1.2 Perancangan <i>Board</i> PCB Integrasi	51
4.2 Hasil Perancangan Mekanik	52

4.3 Hasil Pengujian Parsial Sensor	53
4.3.1 Hasil Pengujian Parsial Sensor Accelerometer.....	55
4.3.2 Hasil Pengujian Parsial Sensor Gyroscope	58
4.3.3 Hasil Pengujian Parsial Sensor Magnetometer	61
4.4 Tahap <i>Pre-Processing</i> Data.....	63
4.4.1 Pengumpulan Data	63
4.4.2 <i>Filtering</i> Data.....	65
4.4.3 <i>Windowing</i> Data.....	67
4.4.4 <i>Split Data Train dan Test</i>	68
4.5 Tahap <i>Training</i> Metode <i>Long Short-Term Memory</i> (LSTM)	69
4.5.1 <i>Training</i> Model dengan Metode LSTM	70
4.5.2 Grafik <i>Accuracy</i> dan <i>Loss</i>	73
4.5.3 Confusion Matrix dan <i>Accuracy Table</i>	75
4.6 Hasil Perancangan Dashboard.....	78
4.7 Hasil Integrasi Alat dengan <i>Dashboard</i>	85
4.8 Pengujian Baterai	86
4.8.1 Perhitungan Teoritis.....	87
4.8.2 Pengujian Langsung.....	89
4.9 Pengujian Sistem Secara <i>Real-Time</i>	92
4.9.1 Pengujian <i>Hardware</i> dengan <i>Software</i>	92
4.9.2 Pengujian Hasil Klasifikasi pada <i>Dashboard</i>	94
4.9.3 Pengujian <i>Latency</i> Sistem.....	101
BAB 5 KESIMPULAN DAN SARAN	105
5.1 Kesimpulan.....	105
5.2 Saran	105
DAFTAR PUSTAKA	107
LAMPIRAN.....	111

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 2.2 Spesifikasi ESP32	18
Tabel 3.1 Analisa kebutuhan sistem	38
Tabel 4.1 Konektivitas ESP32 dengan ICM-20948	55
Tabel 4.2 Hasil Uji Sensor Accelerometer pada Sumbu X	57
Tabel 4.3 Hasil Uji Sensor Aceelerometer pada Sumbu Y	57
Tabel 4.4 Hasil Uji Sensor Aceelerometer pada Sumbu Z.....	58
Tabel 4.5 Hasil Uji Sensor Gyroscope pada Sumbu X	59
Tabel 4.6 Hasil Uji Sensor Gyroscope pada Sumbu Y	60
Tabel 4.7 Hasil Uji Sensor Gyroscope pada Sumbu Z.....	60
Tabel 4.8 Hasil Uji Sensor Magnetometer pada Sumbu X	62
Tabel 4.9 Hasil Uji Sensor Magnetometer pada Sumbu Y	62
Tabel 4.10 Hasil Uji Sensor Magnetometer pada Sumbu Z.....	63
Tabel 4.11 Data yang Telah dilabeli	64
Tabel 4.12 Jumlah Dataset yang digunakan	65
Tabel 4.13 Hasil <i>Windowing</i>	67
Tabel 4.14 Hasil <i>Split Data Train</i> dan <i>Test</i>	69
Tabel 4.15 Hasil Analisis <i>Batch Normalization</i>	72
Tabel 4.16 <i>Classification Report</i>	76
Tabel 4.17 Komponen dan Konsumsi Arusnya.....	87
Tabel 4.18 Pengujian Baterai	89
Tabel 4.19 Pengujian <i>Hardware</i> dengan <i>Software</i>	92
Tabel 4.20 Pengujian Posisi Pengelasan 1G secara <i>Real-Time</i>	94
Tabel 4.21 Pengujian Posisi Pengelasan 2G secara <i>Real-Time</i>	96
Tabel 4.22 Pengujian Posisi Pengelasan 3G secara <i>Real-Time</i>	97
Tabel 4.23 Pengujian Posisi Pengelasan 4G secara <i>Real-Time</i>	99
Tabel 4.24 Pengujian <i>Latency</i> Sistem	101

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 1.1 <i>Shipyards</i> PT. Adiluhung Saranasegara Indonesia.....	3
Gambar 2.1 Posisi Pengelasan (<i>Welding Position</i>)	10
Gambar 2.2 Arsitektur <i>Inertial Measurement Unit</i> (IMU)	11
Gambar 2.3 Chip ESP32	16
Gambar 2.4 ICM-20948	17
Gambar 2.5 Battery	18
Gambar 2.6 <i>Module Charger</i> TP4065.....	19
Gambar 2.7 <i>Welder Glove</i>	20
Gambar 2.8 <i>SD Card</i>	20
Gambar 2.9 <i>Module SD Card</i>	21
Gambar 2.10 Arduino IDE	22
Gambar 2.11 VS Code	23
Gambar 2.12 Python	24
Gambar 3.1 Diagram Blok Sistem	28
Gambar 3.2 Diagram cara kerja sistem software	29
Gambar 3.3 Flow Alur Kerja Sistem.....	31
Gambar 3.4 Diagram Aliran Data Proses	32
Gambar 3.5 Diagram Penelitian	33
Gambar 3.6 Perancangan <i>Hardware electric</i>	37
Gambar 3.7 Perancangan <i>Hardware Mekanik</i>	38
Gambar 3.8 Halaman <i>Login dan Register Dashboard</i>	39
Gambar 3.9 <i>Dashboard Monitoring</i>	40
Gambar 3.10 <i>Welder's Schedule</i>	41
Gambar 3.11 <i>Welder's Schedule</i>	42
Gambar 3.12 Arsitektur Model LSTM.....	43
Gambar 4.1 <i>Design Board</i> ESP32.....	50
Gambar 4.2 <i>Board</i> ESP32	50
Gambar 4.3 <i>Design Board</i> Integrasi	51
Gambar 4.4 <i>Board</i> Integrasi	52
Gambar 4.5 Rancangan Mekanik.....	53

Gambar 4.6 Spesifikasi Perangkat Data Acuan	54
Gambar 4.7 <i>Wiring</i> ESP32 dengan ICM-20948	55
Gambar 4.8 Pengujian Parsial Sensor Accelerometer	56
Gambar 4.9 Pengujian Parsial Sensor Gyroscope	58
Gambar 4.10 Pengujian Parsial Sensor Magnetometer	61
Gambar 4.11 Grafik <i>Filtering</i> Accelerometer	65
Gambar 4.12 Grafik <i>Filtering</i> Gyroscope	66
Gambar 4.13 Grafik <i>Filtering</i> Magnetometer	66
Gambar 4.14 Tabel Hasil <i>Training</i> dengan Metode LSTM.....	70
Gambar 4.15 Grafik <i>Accuracy</i>	74
Gambar 4.16 Grafik <i>Loss</i>	75
Gambar 4.17 Confusion Matrix.....	76
Gambar 4.18 Halaman <i>Login</i> dan <i>Register</i>	78
Gambar 4.19 Halaman Utama <i>Dashboard</i>	79
Gambar 4.20 Tampilan <i>Add Users</i>	80
Gambar 4.21 Tampilan <i>Add Workers</i>	81
Gambar 4.22 Tampilan <i>Manage Users</i>	82
Gambar 4.23 Tampilan <i>Manage Workers</i>	83
Gambar 4.24 Tampilan <i>LSTM Analysis</i>	84
Gambar 4.25 Hasil Integrasi Alat dengan <i>Dashboard</i>	85
Gambar 4.26 Hasil Pengukuran dengan <i>Current Checker</i>	87
Gambar 4.27 Pengujian Posisi Pengelasan 1G.....	95
Gambar 4.28 Pengujian Posisi Pengelasan 2G.....	96
Gambar 4.29 Pengujian Posisi Pengelasan 3G.....	98
Gambar 4.30 Pengujian Posisi Pengelasan 4G.....	99
Gambar 4.31 Pengujian <i>Latency</i> Sistem.....	101
Gambar 4.32 Grafik Hasil Pengujian <i>Latency</i> Sistem.....	103

DAFTAR NOTASI

- f_t : Nilai aktivasi *forget gate*.
- x_t : *Input* pada waktu- t (data IMU/GPS).
- h_{t-1} : *Hidden state* pada waktu sebelumnya.
- W_f, b_f : Bobot dan bias *forget gate*.
- σ : Fungsi sigmoid (0–1) yang menentukan proporsi memori yang dipertahankan.
- i_t : Nilai aktivasi *input gate*.
- $\tilde{C}_t$: Kandidat memori baru.
- W_i, W_c, b_i, b_c : Bobot dan bias *input gate & candidate state*.
- $\tanh$: Fungsi aktivasi non-linear untuk pembentukan fitur baru.
- C_t : *Cell state* saat ini.
- C_{t-1} : *Cell state* sebelumnya.
- $f_t \cdot C_{t-1}$: Bagian memori lama yang dipertahankan.
- $i_t \cdot \tilde{C}_t$: Informasi baru yang ditambahkan ke memori.
- o_t : Nilai aktivasi *output gate*.
- h_t : *Hidden state* (keluaran LSTM).
- W_o, b_o : Bobot dan bias *output gate*.
- h_t : Sebagai fitur masukan ke layer klasifikasi (Dense / Softmax).
- $|H(j\omega)|$: Respon amplitudo filter terhadap frekuensi
- Ω : Frekuensi sinyal masukan

ωc : frekuensi cutoff (batas antara sinyal yang dilewatkan dan diredam)

n : orde filter yang menentukan tingkat ketajaman penyaringan

$\left(\frac{\omega}{\omega c}\right)^{2n}$: faktor yang mempengaruhi tingkat pelemahan sinyal pada frekuensi tertentu.

μ_B : rata-rata (*mean*) pada satu *mini-batch*.

m : jumlah data dalam satu *mini-batch*.

x_i : nilai aktivasi ke- i .

σ_B^2 : variansi *mini-batch*.

x_i : nilai aktivasi ke- i .

$\hat{x}_i$: hasil normalisasi.

x_i : nilai aktivasi ke- i .

σ_B^2 : variansi *mini-batch*.

ε : konstanta kecil untuk menghindari pembagian dengan n

y_i : keluaran (*output*) Batch Normalization.

γ : parameter skala (*scale*).

β : parameter pergeseran (*shift*).

t : waktu operasi baterai (jam)

C : kapasitas baterai (mAh)

I_{total} : konsumsi arus total sistem (mA)

L_{ms} : Latency (ms)

ΔF : Selisih jumlah frame

FPS : Frame rate video (frame per second)

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Proses pengelasan pada konstruksi kapal harus diperhatikan dengan cermat untuk memastikan kualitas las. Hal ini mencakup penggunaan prosedur dan teknik pengelasan yang tepat, pemilihan material yang sesuai, serta penerapan metode pengelasan yang mengikuti *Welding Procedure Specification* (WPS), yang telah memenuhi kualifikasi (Virmansyah et al., 2024). Setiap welder memiliki pola gerak tangan tertentu saat melakukan proses pengelasan, dan pola tersebut dapat menunjukkan kestabilan, kompetensi, serta kualitas hasil pengelasan yang dihasilkan (Pribadi & Shinoda, 2022).

Dalam praktik pengelasan, posisi pengelasan diklasifikasikan berdasarkan orientasi sambungan terhadap arah gravitasi, yaitu posisi 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*). Setiap posisi pengelasan memiliki tingkat kesulitan dan karakteristik teknik yang berbeda, sehingga menuntut penguasaan teknik, kestabilan gerakan tangan, serta kontrol postur tubuh yang baik dari seorang welder. Perbedaan posisi pengelasan menyebabkan variasi tingkat kestabilan proses dan kesulitan pengendalian kolam las, yang secara langsung berpengaruh terhadap kualitas sambungan las, khususnya kekuatan tarik dan karakteristik mekanik hasil pengelasan (Utomo & Yunus, 2021). Posisi pengelasan 1G hingga 4G memiliki tantangan teknis yang berbeda terkait pengaruh gravitasi, arah pengelasan, serta kestabilan gerak tangan welder, sehingga memerlukan kontrol gerakan yang konsisten untuk menghasilkan kualitas pengelasan yang optimal. Variasi orientasi dan posisi pengelasan terbukti memengaruhi sifat mekanik sambungan las akibat perubahan kondisi aliran logam cair dan tingkat kesulitan pengendalian proses selama pengelasan berlangsung (Sulaiman et al., 2024).

Selain keterampilan teknis, pekerjaan pengelasan di lingkungan industri maritim juga menuntut kepatuhan terhadap aspek Keselamatan dan Kesehatan Kerja (K3) serta disiplin kerja. Penelitian menunjukkan bahwa penggunaan *Personal Protective Equipment* (PPE), kepatuhan WPS, serta kompetensi welder berperan penting dalam menurunkan risiko kecelakaan kerja dan paparan bahaya selama proses pengelasan (Penerapan et al., 2024). Di sisi lain, *Safety behaviour*

welder juga dipengaruhi oleh faktor kedisiplinan kerja, seperti kepatuhan terhadap prosedur, jam kerja, dan kesiapan kerja, yang secara langsung berdampak pada konsistensi kualitas hasil las dan keselamatan pekerja (Maharja et al., 2022). Dalam konteks industri galangan kapal, beberapa studi melaporkan bahwa *welder* sering bekerja dalam durasi yang cukup panjang, sehingga evaluasi terkait disiplin kerja dan beban kerja penting dilakukan untuk mencegah peningkatan risiko kelelahan dan kecelakaan (Suheri Jumartika et al., 2021).

Seiring berkembangnya teknologi sensor, penggunaan *multi-sensor Inertial Measurement Unit* (IMU) yang terdiri dari *accelerometer*, *gyroscope*, dan *magnetometer* semakin banyak diterapkan dalam sistem *Human Activity Recognition* (HAR) untuk merekam dan mengenali pola pergerakan manusia secara akurat. Kombinasi beberapa sensor inersia memungkinkan sistem menangkap karakteristik gerak yang lebih kompleks dibandingkan penggunaan sensor tunggal, khususnya pada aktivitas yang melibatkan perubahan postur, orientasi, dan gerakan berulang (Pradani & Mahananto, 2021). Penelitian menunjukkan bahwa pendekatan *multi-sensor* IMU mampu meningkatkan akurasi klasifikasi aktivitas karena data yang dihasilkan bersifat saling melengkapi dan merepresentasikan dinamika gerak manusia secara lebih komprehensif (Rivas-Caicedo et al., 2025). Dalam konteks aktivitas industri, termasuk pengelasan, *multi-sensor* IMU sangat relevan untuk melakukan *tracking* aktivitas *welder* karena mampu merekam gerakan tangan, lengan, dan perubahan postur tubuh selama proses pengelasan berlangsung, yang memiliki pola gerak khas dan berulang. Dengan demikian, penerapan *multi-sensor* IMU pada aktivitas *welder* tidak hanya mendukung pengenalan aktivitas secara otomatis, tetapi juga berpotensi digunakan sebagai alat evaluasi objektif terhadap konsistensi gerak, keterampilan kerja, dan kualitas proses pengelasan.

Meskipun pada berbagai penelitian mengenai pengenalan aktivitas berbasis *multi-sensor* IMU telah dilakukan, Sebagian besar masih berfokus pada aktivitas manusia secara umum dan belum diarahkan secara spesifik pada aktivitas *welder* yang memiliki karakteristik gerak tangan. Selain itu, sistem pemantauan aktivitas pada *welder* umumnya masih dilakukan secara manual tanpa dukungan perangkat sensor dan pengolahan data berbasis kecerdasan buatan, sehingga konsistensi gerak

dan kualitas kerja *welder* sulit untuk dianalisis dan diidentifikasi secara objektif. Kondisi tersebut menunjukkan bahwa masih diperlukan suatu sistem yang mampu merekam dan mengenali pola aktivitas *welder* secara otomatis menggunakan teknologi sensor dan permodelan berbasis *deep learning*.

Dalam implementasinya di lingkungan industri nyata, penelitian ini dilakukan melalui kolaborasi dengan PT. Adiluhung Saranasegara Indonesia yang dapat dilihat pada Gambar 1.1, sebuah perusahaan yang bergerak di bidang industri maritim dan galangan kapal, di mana aktivitas pengelasan merupakan salah satu proses utama dalam konstruksi dan perawatan kapal. Pada kegiatan operasional perusahaan tersebut, welder dihadapkan pada berbagai variasi posisi pengelasan dengan kondisi kerja yang dinamis, sehingga diperlukan konsistensi gerak tangan dan penguasaan teknik yang baik untuk menjamin kualitas hasil las. Namun, proses identifikasi posisi pengelasan serta evaluasi keterampilan welder di lapangan masih cenderung dilakukan secara manual dan bergantung pada pengamatan visual, sehingga berpotensi menimbulkan subjektivitas dan ketidakkonsistenan penilaian. Kondisi ini menunjukkan adanya kebutuhan akan suatu sistem berbasis teknologi sensor yang mampu merekam dan mengklasifikasikan posisi pengelasan secara objektif, khususnya melalui pemanfaatan data pergerakan tangan welder sebagai indikator utama dalam membedakan posisi pengelasan 1G hingga 4G.



Gambar 1.1 Shipyard PT. Adiluhung Saranasegara Indonesia
(Dokumentasi Pribadi Penulis, 2026)

Selain integrasi sensor yang tepat, pemilihan metode pemodelan data juga menjadi aspek penting dalam pengenalan aktivitas berbasis sinyal *time-series* dari

multi-sensor IMU. Metode *deep learning* seperti *Long Short-term Memory* (LSTM) telah banyak digunakan dalam penelitian *Human Activity Recognition* (HAR) karena kemampuannya dalam menangkap pola temporal dari data sekuensial yang kompleks sehingga hasil klasifikasi menjadi lebih akurat dibandingkan teknik konvensional lainnya (Afida et al., 2024). Penelitian lain juga menunjukkan bahwa pendekatan metode LSTM dapat mengolah data IMU secara lebih stabil dan adaptif pada berbagai variasi pergerakan manusia, sehingga menghasilkan performa klasifikasi yang lebih andal dalam lingkungan pengujian yang berbeda (Jaramillo et al., 2022). Dengan karakteristik data gerak pada aktivitas *welder* yang bersifat berulang dan dipengaruhi perubahan gerak tangan, pada penelitian ini penggunaan metode LSTM dinilai sesuai untuk membangun sistem pengenalan pola gerak tangan *welder* berbasis *multi-sensor* IMU.

Berdasarkan permasalahan tersebut, diperlukan suatu sistem yang mampu melakukan pengenalan pola gerakan tangan *welder* secara akurat serta dapat diolah secara otomatis menggunakan metode *deep learning*. Pada penelitian ini peneliti akan mengembangkan sebuah sistem pengenalan pola gerakan tangan *welder* berbasis *multi-sensor* IMU yang terintegrasi dalam platform *embedded system*, sehingga data gerakan tangan *welder* dapat dikumpulkan secara *real-time* selama proses pengelasan berlangsung. Data sensor tersebut kemudian diproses menggunakan metode *deep learning* LSTM untuk mengklasifikasikan pola gerakan tangan *welder*.

Penelitian ini bertujuan untuk merancang, mengembangkan, dan mengimplementasikan sebuah sistem klasifikasi posisi pengelasan (*welding position*) berbasis *multi-sensor* IMU yang difokuskan pada pemetaan pergerakan tangan *welder* selama proses pengelasan berlangsung. Data gerak tangan yang direkam oleh sensor IMU digunakan untuk merepresentasikan perubahan orientasi dan pola gerakan khas pada masing-masing posisi pengelasan, yang selanjutnya diolah menggunakan metode *deep learning* LSTM untuk menghasilkan klasifikasi posisi pengelasan secara otomatis dan akurat.

Melalui penelitian ini, diharapkan dapat diperoleh model klasifikasi posisi pengelasan (*welding position*) yang mampu bekerja secara akurat, adaptif, dan reliabel berdasarkan pola pergerakan tangan *welder* yang direkam menggunakan

multi-sensor IMU. Sistem yang dikembangkan diharapkan dapat mendukung proses evaluasi keterampilan dan konsistensi teknik pengelasan *welder* secara objektif, serta menjadi dasar bagi pengembangan sistem pemantauan dan penilaian proses pengelasan berbasis sensor pada lingkungan industri maritim.

1.2 Rumusan Masalah

Berdasarkan penjelasan latar belakang tersebut, terdapat rumusan masalah sebagai berikut:

1. Bagaimana merancang dan mengimplementasikan sistem klasifikasi posisi pengelasan (*welding position*) 1G-4G berbasis *multi-sensor Inertial Measurement Unit* (IMU) untuk merekam pergerakan tangan *welder* secara *real-time* selama proses pengelasan berlangsung?
2. Bagaimana karakteristik pola pergerakan tangan *welder* yang direkam menggunakan *multi-sensor* IMU pada posisi pengelasan 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*)?
3. Bagaimana kinerja metode *deep learning Long Short-Term Memory* (LSTM) dalam mengklasifikasikan posisi pengelasan berdasarkan data *time-series* pergerakan tangan *welder* yang diperoleh dari *multi-sensor* IMU?

1.3 Batasan Penelitian

Untuk menjaga agar pembahasan penelitian ini tetap terfokus dan selaras dengan tujuan yang ingin dicapai, maka cakupan perancangan, pengembangan, dan pengujian sistem pada penelitian ini dibatasi pada beberapa aspek berikut:

1. Penelitian ini difokuskan pada klasifikasi posisi pengelasan (*welding position*) 1G, 2G, 3G, dan 4G berdasarkan pola pergerakan tangan *welder*, tanpa menganalisis kualitas hasil las secara fisik seperti cacat las atau kekuatan mekanik sambungan.
2. Data gerakan yang digunakan dalam penelitian ini diperoleh dari *multi-sensor Inertial Measurement Unit* (IMU) yang terdiri dari *accelerometer*, *gyroscope*, dan *magnetometer*, yang dipasang pada bagian tangan atau lengan *welder* sebagai representasi utama gerakan selama proses pengelasan.

3. Penelitian ini hanya memanfaatkan data pergerakan tangan *welder* dan tidak membahas aspek keselamatan dan kesehatan kerja (K3), kelelahan, maupun ergonomi kerja secara mendalam.
4. Metode pengolahan dan klasifikasi data yang digunakan dalam penelitian ini dibatasi pada metode *deep learning Long Short-Term Memory* (LSTM), tanpa melakukan perbandingan dengan metode klasifikasi lainnya.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah diatas, terdapat tujuan penelitian sebagai berikut:

1. Merancang dan mengimplementasikan sistem klasifikasi posisi pengelasan (*welding position*) berbasis *multi-sensor Inertial Measurement Unit* (IMU) yang mampu merekam pergerakan tangan *welder* secara *real-time* selama proses pengelasan berlangsung.
2. Menganalisis karakteristik pola pergerakan tangan *welder* pada masing-masing posisi pengelasan berdasarkan data *time-series* yang diperoleh dari *multi-sensor* IMU.
3. Mengimplementasikan dan mengevaluasi kinerja metode *deep learning Long Short-Term Memory* (LSTM) dalam mengklasifikasikan posisi pengelasan berdasarkan data pergerakan tangan *welder* yang direkam menggunakan *multi-sensor* IMU.

1.5 Manfaat Penelitian

Penelitian Tugas Akhir ini diharapkan dapat memberikan manfaat, antara lain:

1. Memberikan kontribusi akademis dalam pengembangan sistem klasifikasi posisi pengelasan berbasis *multi-sensor* IMU dan metode LSTM.
2. Menghasilkan sistem yang mampu merekam dan mengklasifikasikan posisi pengelasan secara otomatis berdasarkan pergerakan tangan *welder*.
3. Menjadi dasar pengembangan sistem pemantauan aktivitas pengelasan berbasis sensor untuk meningkatkan kualitas dan keselamatan kerja.

BAB 2

TINJAUAN PUSTAKA

2.1 Kajian Penelitian Terdahulu

Penelitian terkait aktivitas pengelasan telah banyak dilakukan dengan fokus pada aspek ergonomi dan kualitas hasil las. Estriyanto et al. (2024) menunjukkan bahwa penerapan kaidah ergonomi pada berbagai posisi pengelasan, mulai dari 1G hingga 4G, mampu meningkatkan kenyamanan kerja *welder*, mengurangi tingkat kelelahan, serta memperbaiki kualitas hasil pengelasan. Temuan ini menegaskan bahwa posisi pengelasan memiliki karakteristik kerja yang berbeda dan berdampak langsung pada performa serta kondisi fisik *welder* selama proses pengelasan berlangsung.

Selain aspek ergonomi, variasi posisi pengelasan juga terbukti memengaruhi kualitas mekanik sambungan las. Utomo dan Yunus (2021) menganalisis pengaruh posisi pengelasan 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*) terhadap kekuatan tarik dan kekuatan tekuk sambungan las baja ST 41. Hasil penelitian menunjukkan bahwa perbedaan orientasi pengelasan menyebabkan perubahan kondisi kolam las akibat pengaruh gravitasi, sehingga berdampak signifikan terhadap kualitas dan kekuatan sambungan las. Penelitian ini menjadi dasar bahwa setiap posisi pengelasan memiliki karakteristik teknis yang berbeda dan perlu diklasifikasikan secara tepat.

Dalam konteks pengenalan aktivitas manusia, Pradani dan Mahananto (2021) mengembangkan sistem *Human Activity Recognition* (HAR) menggunakan kombinasi *multi-sensor* IMU yang terdiri dari *accelerometer* dan *gyroscope*. Hasil penelitian menunjukkan bahwa penggunaan *multi-sensor* IMU mampu meningkatkan akurasi pengenalan aktivitas dibandingkan penggunaan sensor tunggal, karena data yang dihasilkan lebih representatif terhadap dinamika gerakan manusia. Penelitian ini membuktikan bahwa data gerak berbasis IMU sangat efektif untuk mengenali pola aktivitas manusia secara otomatis. Penguatan terhadap pendekatan *multi-sensor* IMU juga ditunjukkan oleh Rivas-Caicedo et al. (2025) yang mengusulkan dataset *multi-sensor* untuk pengenalan aktivitas manusia menggunakan data inersia dan orientasi. Hasil penelitian menunjukkan bahwa integrasi beberapa sensor IMU dapat meningkatkan akurasi klasifikasi aktivitas

secara signifikan, karena data dari masing-masing sensor saling melengkapi dalam merepresentasikan perubahan orientasi dan postur tubuh. Penelitian ini menegaskan relevansi penggunaan *multi-sensor* IMU dalam sistem pengenalan aktivitas berbasis data *time-series*.

Dari sisi metode pengolahan data, Malashin et al. (2024) dalam studi review-nya menunjukkan bahwa metode *Long Short-Term Memory* (LSTM) sangat efektif dalam mengklasifikasikan aktivitas manusia berbasis data sensor inersia. LSTM terbukti unggul dalam menangkap pola temporal pada data *time-series*, khususnya pada aktivitas yang bersifat berulang dan berurutan. Hasil pengujian menunjukkan bahwa pendekatan LSTM menghasilkan tingkat akurasi yang lebih tinggi dan stabil dibandingkan metode konvensional, sehingga dinilai sangat sesuai untuk sistem *Human Activity Recognition* (HAR) berbasis IMU. Temuan serupa juga dilaporkan oleh Gaur (2022) yang mengembangkan sistem pengenalan aktivitas manusia menggunakan metode *LSTM-Recurrent Neural Network* (LSTM-RNN) berbasis data sensor *wearable*. Penelitian ini menunjukkan bahwa LSTM mampu mengenali dan mengklasifikasikan aktivitas manusia secara efektif dengan akurasi mencapai 94%. Model LSTM-RNN terbukti mampu menangkap ketergantungan jangka panjang pada data *time-series*, sehingga memberikan performa yang lebih baik dibandingkan metode lain, terutama pada aktivitas yang memiliki pola gerakan kompleks.

Berdasarkan kajian penelitian terdahulu tersebut, dapat disimpulkan bahwa posisi pengelasan memiliki karakteristik teknis dan ergonomis yang berbeda, serta aktivitas *welder* dapat direpresentasikan melalui pola pergerakan tangan. Di sisi lain, penggunaan *multi-sensor* IMU dan metode *deep learning* LSTM terbukti efektif dalam mengenali dan mengklasifikasikan aktivitas manusia berbasis data *time-series*. Namun, hingga saat ini masih terbatas penelitian yang secara spesifik mengintegrasikan *multi-sensor* IMU dan metode LSTM untuk mengklasifikasikan posisi pengelasan berdasarkan pergerakan tangan *welder*, khususnya pada lingkungan industri maritim. Oleh karena itu, penelitian ini dilakukan untuk mengisi celah tersebut dengan mengembangkan sistem klasifikasi posisi pengelasan berbasis *multi-sensor* IMU dan metode LSTM.

2.2 Kajian Pustaka

Dalam Tugas Akhir, kajian pustaka berfungsi sebagai landasan konseptual dan prinsip-prinsip yang mendasari pengembangan penelitian. Hal ini mencakup tinjauan literatur serta konsep-konsep utama yang memperkuat pemahaman tentang konteks penelitian, mendukung penyusunan hipotesis, dan menjadi dasar untuk analisis data. Dengan demikian, dasar teori memberikan landasan intelektual yang diperlukan untuk membangun kerangka penelitian dan memahami fenomena yang sedang diteliti.

2.2.1 Pengelasan pada Konstruksi Kapal

Pengelasan merupakan salah satu proses utama dalam konstruksi kapal karena berperan dalam menyatukan komponen struktur baja sehingga mampu membentuk sambungan yang kuat, stabil, dan aman terhadap beban operasional kapal. Dalam industri maritim, kualitas hasil pengelasan harus dikontrol secara ketat karena berpengaruh langsung terhadap keselamatan struktur dan umur kapal (Virmansyah et al., 2024).

Selain faktor parameter panas, arus, dan material, konsistensi gerakan welder saat melakukan proses pengelasan juga berperan penting terhadap kualitas las. Pola gerak tangan yang stabil membantu menghasilkan jejak pengelasan yang bagus, serta meminimalkan cacat seperti porositas, undercut, dan ketidakrataan permukaan (Pribadi & Shinoda, 2022).

2.2.2 Posisi Pengelasan (*Welding Position*)

Posisi pengelasan merupakan pengaturan orientasi benda kerja dan arah pengelasan terhadap gaya gravitasi selama proses pengelasan berlangsung. Perbedaan posisi pengelasan menyebabkan variasi tingkat kesulitan, stabilitas kolam las, serta teknik pengelasan yang harus dikuasai oleh *welder*. Dalam praktik pengelasan pelat, posisi pengelasan yang umum digunakan dan dijadikan standar adalah posisi 1G, 2G, 3G, dan 4G seperti pada Gambar 2.1 di bawah.

Posisi 1G (flat position) merupakan posisi pengelasan paling dasar, di mana benda kerja berada pada bidang datar dan proses pengelasan dilakukan dari arah atas. Pada posisi ini, pengaruh gravitasi membantu pembentukan kolam las sehingga logam cair mengalir secara stabil dan mudah dikontrol. Gerakan tangan

welder cenderung lurus dan konstan dengan variasi sudut yang relatif kecil, sehingga perubahan orientasi dan percepatan tangan yang terukur oleh sensor IMU berada pada rentang yang lebih stabil dibandingkan posisi lainnya. Posisi 2G (horizontal position) dilakukan pada bidang vertikal dengan arah pengelasan mendatar. Pada posisi ini, gravitasi mulai memengaruhi aliran logam cair ke sisi bawah sambungan, sehingga welder perlu menyesuaikan sudut elektroda dan kecepatan gerak tangan secara lebih presisi. Hal ini menyebabkan adanya variasi sudut rotasi dan perubahan percepatan lateral yang lebih signifikan dibandingkan posisi 1G (Estriyanto et al., 2024).



G = Groove Weld (Las Alur).

1G (Flat): Posisi paling dasar.
Benda kerja datar di bawah tangan.

2G (Horizontal): Benda kerja tegak, pengelasan dilakukan mendatar (kiri ke kanan atau sebaliknya).

3G (Vertical): Las tegak lurus.
Bisa arah naik (uphill) atau turun (downhill).

4G (Overhead): Las di atas kepala. Posisi tersulit di kategori plat karena melawan gravitasi!

Gambar 2.1 Posisi Pengelasan (*Welding Position*)
Sumber (<https://share.google/T2eoOL13GxqiNH8Fc>)


Posisi 3G (vertical position) merupakan posisi pengelasan pada bidang vertikal dengan arah pengelasan ke atas atau ke bawah. Posisi ini memiliki tingkat kesulitan lebih tinggi karena logam cair cenderung mengalir mengikuti gaya

gravitasi, sehingga *welder* harus mengendalikan kolam las melalui kombinasi gerakan tangan yang lebih kompleks, baik secara vertikal maupun rotasional (Sulaiman et al., 2024). Perubahan arah gerak tangan yang dominan ke atas atau ke bawah menghasilkan pola sinyal *accelerometer* dan *gyroscope* yang berbeda secara temporal dibandingkan posisi 1G dan 2G.

Sementara itu, posisi 4G (*overhead position*) merupakan posisi pengelasan paling sulit, di mana benda kerja berada di atas kepala *welder*. Pada posisi ini, pengaruh gravitasi sangat signifikan dan meningkatkan risiko percikan logam cair, sehingga diperlukan kestabilan gerakan tangan dan kontrol orientasi yang sangat tinggi (Sulaiman et al., 2024). Gerakan tangan pada posisi 4G cenderung lebih terbatas namun intens, dengan perubahan orientasi yang tajam akibat posisi kerja yang tidak ergonomis. Perbedaan karakteristik gerakan tangan, orientasi tubuh, dan beban kerja pada posisi 1G hingga 4G inilah yang menjadi dasar pemanfaatan data IMU untuk membedakan posisi pengelasan secara objektif melalui sistem monitoring dan klasifikasi aktivitas *welder* berbasis sensor.

2.2.3 Inertial Measurement Unit (IMU)

Inertial Measurement Unit (IMU), merupakan perangkat sensor yang terdiri dari tiga komponen utama, yaitu *accelerometer*, *gyroscope*, dan *magnetometer*. Seperti yang terlihat pada Gambar 2.2 Arsitektur IMU di bawah. *Accelerometer* digunakan untuk mengukur kecepatan sudut atau rotasi, *gyroscope* digunakan untuk mengukur kecepatan sudut atau rotasi; dan *magnetometer* digunakan untuk mengukur orientasi terhadap medan magnet bumi sebagai referensi arah. Data yang dihasilkan oleh IMU berbentuk sinyal *time-series*, sehingga sangat sesuai jika digunakan untuk menganalisis gerakan tubuh manusia dalam bentuk urutan waktu yang berkelanjutan (Jaramillo et al., 2023).



Gambar 2.2 Arsitektur *Inertial Measurement Unit* (IMU)

Sumber (<https://ww2.mathworks.cn/help/nav/ug/model-imu-gps-and-insgps.html>)

Dalam beberapa tahun terakhir, IMU banyak digunakan sebagai sensor wearable untuk analisis gerakan manusia karena memiliki keunggulan berupa ukuran yang ringkas, biaya relatif rendah, serta kemampuan beroperasi di lingkungan nyata tanpa keterbatasan ruang seperti pada sistem berbasis kamera. Penggunaan IMU *wearable* juga telah berkembang ke aplikasi industri dan pemantauan aktivitas kerja nyata, termasuk untuk pelacakan gerakan tangan, postur tubuh, serta aktivitas berulang, yang menjadikannya solusi yang fleksibel dan efisien untuk merekam data gerakan dalam kondisi kerja sesungguhnya (Digo et al., 2022).

Pada penerapannya, data dari *accelerometer*, *gyroscope*, dan *magnetometer* umumnya diproses menggunakan teknik sensor fusion untuk menghasilkan estimasi orientasi dan pergerakan yang lebih akurat serta mengurangi pengaruh *noise* dan *drift* sensor. Studi sistematis menunjukkan bahwa IMU wearable mampu menghasilkan estimasi parameter kinematik yang baik bila dibandingkan dengan sistem pengukuran optik, meskipun tantangan seperti gangguan medan magnet dan akumulasi kesalahan tetap perlu diperhatikan, terutama pada pengambilan data berdurasi panjang. Oleh karena itu, pemilihan metode pengolahan data yang tepat menjadi faktor penting dalam pemanfaatan IMU untuk analisis gerakan manusia, terutama pada konteks industri dan aktivitas kerja seperti pengelasan (Prisco et al., 2025).

2.2.4 Human Activity Recognition (HAR)

Human Activity Recognition (HAR) adalah bidang penelitian yang berfokus pada identifikasi dan klasifikasi aktivitas manusia berdasarkan data sensor, terutama sensor seperti multi-sensor IMU yang merekam percepatan, rotasi, dan orientasi tubuh. HAR banyak diterapkan dalam berbagai aspek seperti kesehatan, olahraga, keamanan, dan interaksi manusia-komputer karena kemampuannya dalam memetakan pola perilaku manusia secara otomatis tanpa bergantung pada pengawasan manual. Dengan kemajuan teknologi sensor dan komputasi, data gerakan tubuh kini dapat diukur secara *real-time* dan akurat melalui perangkat *wearable* atau *smartphone* yang dilengkapi sensor *accelerometer*, *gyroscope*, dan *magnetometer*, yang kemudian diolah untuk mengenali pola aktivitas tertentu (He et al., 2024).

2.2.5 Deep Learning untuk Data Time-Series

Deep learning memiliki peran penting dalam pengolahan data *time-series*, khususnya pada aplikasi pengenalan aktivitas manusia berbasis *multi-sensor* IMU. Berbeda dengan *machine learning* konvensional yang membutuhkan proses ekstraksi fitur secara manual, model *deep learning* mampu mempelajari representasi fitur secara otomatis langsung dari sinyal mentah. Arsitektur seperti *Convolution Neural Network* (CNN) dan *Recurrent Neural Network* (RNN) banyak digunakan untuk memodelkan struktur temporal dan spasial pada data gerak manusia (Carlos et al., 2024).

Pada konteks *Human Activity Recognition* (HAR), pendekatan *deep learning* terbukti mampu menghasilkan akurasi yang lebih tinggi dan stabil ketika diterapkan pada data *multi-sensor* IMU yang bersifat *non-linear* dan memiliki variasi gerak yang kompleks. Studi empiris menunjukkan bahwa model *deep learning* mampu mempelajari hubungan jangka panjang dalam data sekuensial, sehingga lebih adaptif terhadap perbedaan pola gerak antara pengguna maupun kondisi lingkungan pengujian (Afida et al., 2024).

2.2.6 Metode Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *deep learning* yang dikembangkan untuk mengatasi tantangan dalam memproses data sekuensial. Secara umum, LSTM merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang khusus untuk menangkap pola temporal jangka panjang dalam rangkaian data, sehingga mampu mempelajari hubungan antara data yang terjadi dalam berbagai rentang waktu. Struktur LSTM terdiri dari unit-unit memori dengan mekanisme *gate*, seperti *input gate*, *forget gate*, dan *output gate* yang bekerja untuk mengontrol aliran informasi masuk dan keluar dari sel memori (Malashin et al., 2024). Mekanisme *gate* seperti itu dapat meminimalkan permasalahan vanishing gradient pada data sekuensial yang panjang selama proses pembelajaran (Sinha et al., 2023).

Secara matematis, proses komputasi pada LSTM dapat dirumuskan sebagai berikut:

- *Forget gate*

Forget gate digunakan untuk menentukan seberapa besar informasi pada memori sebelumnya:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.1)$$

Di mana:

f_t : nilai aktivasi *forget gate*

x_t : input pada waktu- t (data IMU/GPS)

h_{t-1} : *hidden state* pada waktu sebelumnya

W_f, b_f : bobot dan bias *forget gate*

σ : fungsi sigmoid (0–1) yang menentukan proporsi memori yang dipertahankan

- *Input Gate*

Input gate digunakan untuk menentukan dan memilah informasi baru yang disimpan ke dalam memori:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.2)$$

Nilai kandidat *cell state* dihitung dengan:

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.3)$$

Di mana:

i_t : nilai aktivasi *input gate*

$\tilde{C}_t$: kandidat memori baru

W_i, W_C, b_i, b_C : bobot dan bias *input gate* dan *candidate state*

$\tanh$: fungsi aktivasi *non-linear* untuk pembentukan fitur baru

- *Update Cell State*

Update cell state digunakan untuk menggabungkan memori lama dan informasi baru:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.4)$$

Di mana:

C_t : *cell state* saat ini

C_{t-1} : *cell state* sebelumnya

$f_t \cdot C_{t-1}$: bagian memori lama yang dipertahankan

$i_t \cdot \tilde{C}_t$: informasi baru yang ditambahkan ke memori

- *Output Gate*

Output gate menghasilkan representasi fitur temporal untuk proses klasifikasi:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.5)$$

Hidden state dihitung dengan:

$$h_t = o_t \odot \tanh(C_t) \quad (2.6)$$

Di mana:

o_t : nilai aktivasi *output gate*

h_t : *hidden state* (keluaran LSTM)

W_o, b_o : bobot dan bias *output gate*

h_t : sebagai fitur masukan ke layer klasifikasi (Dense / Softmax)

Pada penelitian Tugas Akhir ini, metode *Long Short-Term Memory* (LSTM) digunakan untuk memodelkan pola temporal pada data *time-series* yang dihasilkan oleh *multi-sensor* IMU, sehingga sistem mampu mengenali perubahan posisi pengelasan 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*) secara lebih akurat dan stabil dari waktu ke waktu. LSTM dipilih karena memiliki kemampuan untuk mempelajari hubungan temporal jangka panjang pada sinyal sensor, di mana pola gerakan tangan dan perubahan postur tubuh *welder* tidak hanya dipengaruhi oleh kondisi sesaat, tetapi oleh urutan gerakan yang terjadi secara kontinu.


2.3 Hardware dan Software yang Digunakan

Pada Tugas Akhir ini membutuhkan sejumlah *hardware* dalam pengerjaannya. Adapun beberapa *hardware* tersebut adalah:

2.3.1 ESP32 Microcontroller

ESP32 seperti yang ada pada Gambar 2.3 di bawah, merupakan sebuah mikrokontroler berperforma tinggi yang dirancang khusus untuk aplikasi *embedded system* dan *Internet of Things* (IoT). Menurut analisis komprehensif dalam literatur terkini, ESP32 menawarkan fitur yang lengkap seperti prosesor dual-core 32-bit, konektivitas Wi-Fi, bluetooth, dan dukungan komunikasi antarmuka seperti I²C, SPI, UART yang esensial untuk menghubungkan berbagai perangkat sensor seperti IMU dan GPS dalam satu sistem. Hal ini menjadikan ESP32 ideal sebagai

pengontrol dalam embedded system yang membutuhkan pemrosesan data sensor secara real-time, pengiriman data nirkabel, dan integrasi dengan modul lain tanpa membutuhkan perangkat tambahan (Pangarkar et al., 2025).



Gambar 2.3 Chip ESP32
(Sumber: <https://www.studiopieters.nl>)

Dalam konteks aplikasi embedded system berbasis sensor, ESP32 telah dilaporkan memiliki kinerja yang stabil dalam sampling dan akuisisi data dari berbagai sensor secara bersamaan, sehingga mampu memenuhi kebutuhan pengolahan data sensor seperti sinyal IMU yang bersifat cepat dan kontinu. Penelitian menunjukkan bahwa ESP32 dapat menangani *sampling* dengan *rate* tinggi tanpa terjadi bottleneck pada sistem akuisisi data, serta mendukung implementasi *real-time* data processing dan *wireless transmission* (Espinosa-Gavira et al., 2024).

Adapun spesifikasi dari ESP32 dapat diamati pada Tabel 2.1 di bawah ini.

Tabel 2.1 Spesifikasi ESP32

Parameter	Spesifikasi
CPU	Tensilica Xtensa Dual-Core 32-bit LX6 microprocessor 160MHz/240MHz
Tegangan Suplai	2.3V – 3.6V
Konsumsi Arus	500mA
Wireless connectivity	Wifi, Bluetooth legacy, dan Bluetooth Low Energy (BLE)
Bandwidth	7.8 kHz – 500kHz

Parameter	Spesifikasi
ROM	448kB
SRAM	520KB
Peripheral	SPI, UART, ADC, DAC, I2C, 2s, Touch Capacitive, PWM
Sensitivitas	-111dBm – 148dBm
Jumlah I/O	34
Ukuran	19mm x 25.5mm

(Sumber: www.espressif.com)

Pada penelitian Tugas Akhir ini, ESP32 bertugas untuk melakukan akuisisi data secara real-time dari multi-sensor IMU (accelerometer, gyroscope, dan magnetometer) yang terintegrasi dengan modul GPS.

2.3.2 ICM-20948

Sensor inertial Measurement Unit (IMU) ICM-20948 seperti yang terlihat pada Gambar 2.4 dibawah merupakan komponen utama dalam pengukuran gerak pada sistem pengenalan aktivitas *welder* yang dirancang pada Tugas Akhir ini. ICM-20948 adalah perangkat sensor MEMS 9-axis yang mengintegrasikan tiga uni pengukuran utama, yaitu *accelerometer* (3-axis), *gyroscope* (3-axis), *magnetometer* (3-axis) dalam satu paket kecil berukuran 3x3x1 mm, yang mendukung komunikasi antarmuka digital seperti I²C dan SPI. Sensor ini dirancang untuk konsumsi daya yang rendah namun memiliki kemampuan pelacakan orientasi yang komprehensif, sehingga sering digunakan pada aplikasi *wearable*, IoT, dan pemantauan gerak yang membutuhkan ukuran kecil sekaligus presisi tinggi.



Gambar 2.4 ICM-20948

(Sumber: : <https://invensense.tdk.com/products/motion-tracking/9-axis/icm-20948/>)

Dalam konteks penelitian berbasis sensor gerak, penggunaan IMU yang mampu menangkap sinyal percepatan linier, kecepatan sudut, dan medan magnet

sangat penting untuk memperoleh data *time-series* yang merepresentasikan pola gerak tubuh secara menyeluruh. Sensor seperti ICM-20948 secara praktis banyak dipilih karena menyediakan rentang pengukuran penuh untuk *accelerometer*, *gyroscope*, dan *magnetometer*; sehingga memadai untuk analisis berbagai postur dan gerakan tubuh, termasuk aktivitas berdiri, duduk, dan berbaring yang menjadi fokus kajian dalam penelitian ini.

2.3.3 Li-Po 3.7V



Gambar 2.5 Battery


(Sumber <https://share.google/mmweAiBiCqwgYvTos>)

Lithium-Polymer (Li-Po) *battery* yang terlihat pada Gambar 2.5 di atas merupakan salah satu jenis baterai lithium yang banyak digunakan pada sistem elektronik portabel dan *embedded system* karena memiliki densitas energi yang tinggi, bobot yang ringan, serta bentuk yang fleksibel. Li-Po *battery* bekerja pada tegangan nominal 3.7 V per sel dan mampu menyediakan kapasitas energi yang besar dalam ukuran yang relatif kecil, sehingga sesuai untuk aplikasi *wearable* dan sistem *monitoring* berbasis sensor. Selain itu, Li-Po *battery* memiliki karakteristik *self-discharge* yang rendah serta efisiensi pengisian daya yang baik dibandingkan baterai konvensional lainnya mekanik (Karlina et al., 2021)

2.3.4 Modul Charger

bentuk fisik modul charger TP4056 yang digunakan sebagai rangkaian pengisian daya baterai lithium-ion (Li-ion) atau lithium-polymer (Li-Po) satu sel dengan tegangan nominal 3,7 V dapat dilihat pada gambar 2.6 dibawah. Modul ini menggunakan IC TP4056 battery charger IC yang bekerja dengan metode *constant current/constant voltage* (CC/CV), sehingga proses pengisian berlangsung secara

otomatis dan aman hingga tegangan baterai mencapai 4,2 V. Modul TP4056 umumnya menerima tegangan masukan sebesar 5 V melalui konektor USB dan dilengkapi dengan indikator LED untuk menunjukkan status pengisian, yaitu saat baterai sedang diisi dan ketika pengisian telah selesai.



Gambar 2.6 Module Charger TP4065

(Sumber: <https://www.electrothink.com/2024/02/tp4056-lithium-cell-charger-module.html>)

Pada penelitian ini, modul TP4056 digunakan sebagai rangkaian pengisian ulang baterai pada sistem *welding glove* berbasis sensor IMU. Modul ini memungkinkan baterai yang digunakan sebagai sumber daya perangkat dapat diisi kembali dengan mudah tanpa harus melepas baterai dari rangkaian utama. Dengan adanya modul TP4056, sistem dapat bekerja secara portabel dan lebih praktis, sehingga perangkat dapat digunakan secara berulang dalam proses pengambilan data sensor dan pengujian model LSTM untuk pengenalan posisi pengelasan.

2.3.5 CaldWell Glove

CaldWell *glove* seperti pada Gambar 2.7 di bawah merupakan sarung tangan pelindung yang dirancang khusus untuk pekerjaan pengelasan dengan mempertimbangkan aspek keselamatan, kenyamanan, dan fleksibilitas gerakan tangan. Sarung tangan ini umumnya terbuat dari bahan kulit tahan panas dan percikan api, sehingga mampu melindungi tangan welder dari paparan suhu tinggi, percikan logam cair, serta risiko luka akibat proses pengelasan. Penggunaan sarung tangan pengelasan menjadi bagian penting dalam penerapan keselamatan dan kesehatan kerja (K3) pada industri perkapalan.



Gambar 2.7 Welder Glove

(Sumber: <https://caldwell-tech.com/caldwell/cutting-welding-outfit/welding-gloves/>)

Dalam penelitian ini, CaldWell *glove* digunakan sebagai media pemasangan perangkat *wearable* sensor berbasis *multi-sensor* IMU. Pemilihan sarung tangan ini didasarkan pada karakteristiknya yang ergonomis serta tidak menghambat pergerakan tangan *welder* saat bekerja. Pemasangan sensor pada sarung tangan memungkinkan perekaman data gerakan tangan secara langsung dan akurat, sehingga pola gerakan tangan *welder* dapat direkam tanpa mengganggu aktivitas pengelasan.

2.3.6 SD Card dan Module SD Card



Gambar 2.8 SD Card

(Sumber: https://www.galaxy.co.id/products/memory-microsd-sandisk-ultra-32gb-120mb-s-memori-micro-sd-original?srsId=AfmBOoqniRML5a5vA9HbOR_egfTXL4Tfzp9iqiwJ0OlzqBAO2WOfkdUR)

Bentuk fisik SD Card (*Secure Digital Card*) yang digunakan sebagai media penyimpanan data pada penelitian ini dapat dilihat pada Gambar 2.8 di atas. SD Card merupakan perangkat penyimpanan *non-volatile* yang mampu menyimpan data secara permanen meskipun catu daya dimatikan. Media penyimpanan ini memiliki ukuran yang kecil, kapasitas yang cukup besar, serta banyak digunakan pada sistem *embedded*. Pada penelitian ini, SD Card digunakan untuk menyimpan

data hasil pembacaan sensor IMU berupa data accelerometer dan gyroscope yang diperoleh dari welding glove selama proses pengambilan data pada berbagai posisi pengelasan.



Gambar 2.9 *Module SD Card*


(Sumber: <https://components101.com/modules/micro-sd-card-module-pinout-features-datasheet-alternatives>)

Sedangkan Gambar 2.9 di bawah menunjukkan modul *SD Card* yang berfungsi sebagai antarmuka antara *SD Card* dengan mikrokontroler, yaitu ESP32 microcontroller. Modul ini menggunakan komunikasi SPI (*Serial Peripheral Interface*) untuk proses pertukaran data dan dilengkapi dengan rangkaian pendukung seperti regulator tegangan agar *SD Card* dapat bekerja dengan stabil. Dalam penelitian ini, modul *SD Card* memungkinkan proses pencatatan data sensor dilakukan secara otomatis dan *real-time*. Data yang tersimpan pada *SD Card* selanjutnya digunakan sebagai dataset untuk proses pelatihan dan pengujian model *Long Short-Term Memory* (LSTM) dalam mengenali posisi pengelasan 1G, 2G, 3G, dan 4G.

2.3.7 Arduino IDE

Arduino IDE (*Integrated Development Environment*) merupakan perangkat lunak *opensource* yang umum digunakan untuk menulis, mengedit, dan mengunggah program pada mikrokontroler seperti ESP32, arduino uno, dan perangkat *embedded* lain. Arduino IDE menyediakan antarmuka yang sederhana serta dukungan libraries yang cukup beragam, sehingga mempermudah penulisan kode C/C++ untuk berinteraksi dengan berbagai sensor dan modul secara langsung. Arduino IDE memungkinkan pengembaang untuk menghubungkan sensor-sensor seperti IMU dan GPS melalui komunikasi antarmuka (misalnya I²C dan UART), membaca data sensor, dan mengirimkan data tersebut ke perangkat lain atau server

untuk diproses lebih lanjut .Berikut adalah tampilan *software* Arduino IDE pada Gambar 2.10 berikut.



Gambar 2.10 Arduino IDE
(Sumber: Dokumentasi Pribadi Penulis, 2026)


Banyak kemampuan dalam Arduino IDE yang dapat dimanfaatkan untuk membangun berbagai jenis proyek. *Software* Arduino IDE terdiri dari tiga bagian diantaranya:

- Editor: program yang ditulis dalam bahasa pemrosesan disebut editor program. Sketch merupakan daftar atau kode program pada Arduino IDE
- Compiler: Modul ini mengubah kode program dari bahasa pemrosesan menjadi kode biner, yang merupakan satu-satunya bahasa pemrograman yang dapat dipahami oleh mikrokontroler
- Uploader atau modul pengunggah, yang digunakan untuk memprogram kode biner ke dalam memori mikrokontroler.

2.3.8 Visual Studio Code

Visual Studio Code (VS Code) merupakan *source-code editor* ringan yang dikembangkan oleh Microsoft dan banyak digunakan dalam kegiatan pengembangan perangkat lunak. VS Code mendukung berbagai bahasa pemrograman melalui sistem *extensions*, sehingga pengguna dapat menyesuaikan fitur editor sesuai kebutuhan pengembangan, seperti Python, C/C++, dan JavaScript. Tampilan antarmuka Visual Studio Code yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.11 di bawah, yang memperlihatkan

lingkungan pengembangan terintegrasi untuk penulisan, pengujian, dan analisis kode program.



Gambar 2.11 Visual Studio Code
(Sumber: Dokumentasi Pribadi Penulis, 2026)

VS Code dilengkapi dengan berbagai fitur pendukung pengembangan perangkat lunak, antara lain *syntax highlighting*, *code completion*, *integrated terminal*, serta dukungan *version control* berbasis Git. Fitur-fitur tersebut memudahkan proses penulisan, pengujian, dan pengelolaan kode dalam satu lingkungan kerja yang terintegrasi. Selain itu, dukungan *debugging* dan manajemen ekstensi pada VS Code memungkinkan proses pengembangan sistem dilakukan secara lebih efisien dan terstruktur.

Pada penelitian ini, VS Code digunakan sebagai *development environment* untuk proses *preprocessing* data sensor IMU, pelatihan model LSTM, serta eksekusi program klasifikasi aktivitas welder berbasis Python. Pemilihan VS Code didasarkan pada sifatnya yang fleksibel, ringan, dan mudah dikonfigurasi, sehingga mendukung proses eksperimen pemodelan serta dokumentasi kode secara sistematis selama tahap pengembangan sistem.

2.3.9 Python

Python merupakan bahasa pemrograman tingkat tinggi yang banyak digunakan dalam pengembangan sistem berbasis data dan kecerdasan buatan karena sintaksnya yang sederhana, fleksibel, serta didukung oleh ekosistem pustaka yang sangat luas.(Alfarizi et al., 2023). Pada penelitian ini, Python digunakan sebagai bahasa utama dalam pengolahan data sensor IMU, mulai dari tahap *preprocessing*, pemodelan, hingga proses klasifikasi posisi pengelasan menggunakan metode *Long*

Short-Term Memory (LSTM). Representasi Python sebagai bahasa pemrograman yang digunakan dalam sistem ditunjukkan pada Gambar 2.12 dibawah ini, yang menggambarkan peran Python sebagai inti pemrosesan data dalam penelitian ini.



Gambar 2.12 Python

(Sumber: <https://logos-world.net/download-image/>)

Python mendukung berbagai pustaka yang relevan untuk pengolahan data dan pembelajaran mesin, seperti NumPy dan Pandas untuk manipulasi dan analisis data numerik, serta TensorFlow atau Keras untuk implementasi model LSTM. Selain itu, Python juga digunakan untuk mengelola komunikasi dengan basis data MongoDB melalui pustaka PyMongo, sehingga memungkinkan proses penyimpanan dan pengambilan data sensor dilakukan secara efisien. Integrasi berbagai pustaka tersebut menjadikan Python sebagai platform yang efektif untuk membangun sistem pengenalan aktivitas welder berbasis data sensor dan *deep learning*.

Berdasarkan karakteristik tersebut, penggunaan Python dalam penelitian ini diharapkan mampu mendukung proses pengolahan data sensor IMU dan klasifikasi posisi pengelasan secara akurat dan terstruktur. Fleksibilitas Python dalam integrasi perangkat lunak serta kemampuannya dalam menangani pemrosesan data berskala besar menjadikan bahasa pemrograman ini sesuai untuk kebutuhan sistem monitoring dan analisis aktivitas welder yang dikembangkan.

2.3.10 HTTP

Hypertext Transfer Protocol (HTTP) merupakan protokol komunikasi yang digunakan untuk pertukaran data antara client dan server melalui jaringan komputer. HTTP bekerja menggunakan mekanisme request dan response, yaitu

client mengirimkan permintaan data kepada server kemudian server memberikan tanggapan sesuai permintaan tersebut. Pada sistem *Internet of Things* (IoT), HTTP banyak digunakan karena memiliki implementasi yang sederhana, mudah dikembangkan, serta kompatibel dengan berbagai platform pemrograman dan perangkat mikrokontroler (Adriansyah et al., 2026).

Pada penelitian ini, HTTP digunakan sebagai media komunikasi antara mikrokontroler pada welding glove dengan server lokal berbasis Python. Data dari sensor *Inertial Measurement Unit* (IMU) dikirimkan menggunakan metode HTTP POST dalam format JSON untuk selanjutnya diproses menggunakan metode Long Short-Term Memory (LSTM). Penggunaan HTTP dipilih karena mampu mendukung pengiriman data sensor secara real-time dan mempermudah integrasi antara perangkat keras, backend Python, serta dashboard monitoring yang digunakan untuk menampilkan hasil klasifikasi posisi pengelasan.

(Halaman ini sengaja dikosongkan)

BAB 3

METODE PENELITIAN


3.1 Konsep Penelitian

Konsep penelitian pada tugas akhir ini berfokus pada perancangan dan pengembangan sistem klasifikasi posisi pengelasan (*welding position*) berbasis *embedded system* dengan memanfaatkan *multi-sensor Inertial Measurement Unit* (IMU) sebagai perangkat akuisisi data, serta metode *deep learning Long Short-Term Memory* (LSTM) sebagai model klasifikasi. Sistem ini dirancang untuk merekam data pergerakan dan orientasi tangan welder dalam bentuk sinyal *time-series*, kemudian data tersebut diproses dan diklasifikasikan ke dalam beberapa kategori posisi pengelasan, yaitu posisi 1G, 2G, 3G, dan 4G.

Konsep penelitian ini melibatkan tiga komponen utama, yaitu perangkat akuisisi data sensor, perangkat pemrosesan dan penyimpanan data, serta model klasifikasi berbasis LSTM. *Multi-sensor* IMU yang terintegrasi dengan mikrokontroler ESP32 digunakan untuk mengukur percepatan linier, kecepatan sudut, dan orientasi gerakan tangan welder secara *real-time*. Data yang diperoleh kemudian disimpan dan ditransfer ke perangkat pemrosesan untuk dilakukan tahap *pre-processing*, segmentasi data (*windowing*), serta pembentukan dataset sebelum digunakan pada proses pelatihan dan pengujian model LSTM untuk menghasilkan klasifikasi posisi pengelasan secara otomatis.

3.1.1 Diagram Blok Sistem

Diagram blok sistem pada penelitian ini menjelaskan hubungan antar komponen utama pada perangkat klasifikasi posisi pengelasan (*welding position*) berbasis *embedded system* dengan sensor IMU. Sistem dibagi ke dalam tiga bagian utama seperti yang ada pada Gambar 3.1, yaitu bagian input, proses, dan output, di mana setiap bagian memiliki peran yang saling terintegrasi dalam proses akuisisi data, pengolahan sinyal, hingga klasifikasi aktivitas welder menggunakan metode *deep learning Long Short-Term Memory* (LSTM).



Gambar 3.1 Diagram Blok Sistem
(Sumber: Dokumentasi Pribadi Penulis, 2026)


Pada bagian *input*, sistem menggunakan tiga jenis sensor inersia yang terdapat pada modul IMU, yaitu *accelerometer*, *gyroscope*, dan *magnetometer*. Sensor *accelerometer* berfungsi untuk mengukur percepatan linier gerakan tangan *welder*, sensor *gyroscope* digunakan untuk mendeteksi kecepatan sudut dan perubahan orientasi tangan, sedangkan sensor *magnetometer* berfungsi untuk memberikan referensi arah terhadap medan magnet bumi. Kombinasi ketiga sensor ini menghasilkan data pergerakan tangan *welder* yang merepresentasikan pola gerak pada setiap posisi pengelasan.

Pada bagian proses, data mentah dari sensor IMU dibaca oleh mikrokontroler ESP32 secara *real-time*. Data sensor yang telah dibaca kemudian disimpan dalam format CSV sebagai data *time-series*. Selanjutnya, data tersebut ditransfer ke sistem pengolahan untuk dilakukan tahap *pre-processing*, yang meliputi pembersihan data, normalisasi, serta proses *windowing* untuk membagi data menjadi segmen-segmen tertentu. Data hasil *pre-processing* kemudian digunakan pada tahap *training* dengan metode *Long Short-Term Memory* (LSTM) untuk mempelajari pola temporal dari pergerakan tangan *welder*.

Pada bagian *output*, sistem menghasilkan data klasifikasi posisi pengelasan, yaitu 1G, 2G, 3G, dan 4G. Hasil klasifikasi ini merepresentasikan posisi pengelasan berdasarkan pola pergerakan tangan *welder* yang direkam oleh *multi-sensor* IMU. *Output* tersebut selanjutnya dapat digunakan sebagai dasar untuk analisis aktivitas *welder* serta evaluasi keterampilan dan konsistensi teknik pengelasan.

3.1.2 Diagram Cara Kerja Sistem Software

Proses pengolahan, pengiriman, dan penyimpanan data posisi pengelasan (*welding position*) sampai bisa dimunculkan oleh *dashboard* dapat dilihat pada Gambar 3.2 diagram cara kerja sistem *software* berikut berikut:



Gambar 3.2 Diagram cara kerja sistem software
(Sumber : Dokumentasi Pribadi Penulis, 2026)


Proses dimulai dengan multi-sensor IMU yang merekam gerakan tangan *welder* secara real-time, menghasilkan data *time-series* berupa percepatan dan rotasi dari pergerakan tangan *welder*. Sinyal sensor tersebut dibaca oleh mikrokontroler ESP32 melalui komunikasi antarmuka yang sesuai, kemudian

dikirimkan ke laptop untuk diproses lebih lanjut. Data mentah yang diterima selanjutnya disimpan dalam format CSV agar dapat digunakan sebagai dataset pada tahapan pengolahan dan analisis offline. Tahap berikutnya adalah *preprocessing* data, di mana data *time-series* dibersihkan, diseleksi, dan diolah menggunakan teknik *windowing* untuk membagi sinyal ke dalam beberapa segmen data dengan ukuran tertentu. Setiap segmen merepresentasikan rentang waktu tertentu yang akan dijadikan *input* bagi model *deep learning*. Setelah proses *preprocessing* selesai, segmen data tersebut digunakan pada proses pelatihan dan pengujian model *Long Short-Term Memory* (LSTM). Pada tahap ini, model dilatih untuk mengenali pola temporal khas dari pergerakan tangan *welder* sehingga dapat membedakan variasi pola gerakan tangan *welder* berdasarkan karakteristik sinyal gerak.

Setelah model berhasil dilatih dan mencapai performa klasifikasi yang baik, sistem digunakan untuk melakukan proses inferensi terhadap data aktivitas baru. Model LSTM kemudian menghasilkan output berupa posisi pengelasan (*welding position*) 1G, 2G, 3G, dan 4G. Hasil klasifikasi tersebut dipadukan dengan informasi waktu (*timestamp*) sebagai penanda urutan kejadian, kemudian dikirimkan ke server dan disimpan di dalam database sebagai data histori aktivitas. Data hasil klasifikasi yang telah tersimpan pada *database* selanjutnya ditampilkan melalui *dashboard monitoring*. *Dashboard* berfungsi sebagai antarmuka *visual* bagi pengguna untuk memantau status posisi pengelasan (*welding position*) *welder* secara *real-time* sekaligus meninjau riwayat posisi pengelasan (*welding position*) yang telah direkam oleh sistem. Dengan demikian, alur kerja *software* pada sistem ini tidak hanya memungkinkan proses klasifikasi posisi pengelasan (*welding position*) berbasis LSTM, tetapi juga mendukung proses penyimpanan dan penyajian informasi aktivitas secara terstruktur melalui *platform monitoring*.

3.1.3 Flowchart Alur Kerja Sistem

Pada Gambar 3.3, Alur kerja sistem dimulai dengan multi-sensor IMU yang membaca pola gerakan tangan *welder* secara *real-time*.




Gambar 3.3 Flow Alur Kerja Sistem
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Data yang dihasilkan berupa informasi gerakan tangan *welder* selama melakukan pekerjaan. Data sensor tersebut kemudian dikirimkan oleh mikrokontroler ESP32 ke server sebagai masukan sistem. Setelah data diterima, server melakukan proses klasifikasi posisi pengelasan (*welding position*) menggunakan model *Long Short-Term Memory* (LSTM) yang telah dilatih sebelumnya. Model LSTM digunakan untuk mengenali pola gerakan tangan *welder* berdasarkan data sensor yang masuk. Selanjutnya, sistem melakukan pengecekan untuk memastikan bahwa proses klasifikasi berjalan dengan baik.

Apabila klasifikasi berhasil, hasil pengenalan aktivitas *welder* disimpan ke dalam basis data sistem. Data yang tersimpan kemudian dibaca oleh *dashboard monitoring* dan ditampilkan kepada pengguna dalam bentuk informasi posisi pengelasan (*welding position*). Proses ini berlangsung secara berulang selama sistem aktif hingga sistem dihentikan.

3.1.4 Diagram Aliran Data Proses

Gambar 3.4 di bawah menjelaskan mengenai proses aliran data pada sistem monitoring aktivitas *welder*. Dimulai dari perangkat *multi-sensor* IMU yang terpasang pada *welder*; di mana sensor merekam data pola gerakan tangan *welder* selama aktivitas pengelasan.




Gambar 3.4 Diagram Aliran Data Proses
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Data mentah dari sensor tersebut dikirimkan ke mikrokontroler ESP32 sebagai pengolah awal dan perangkat komunikasi nirkabel. Selanjutnya, ESP32 meneruskan data aktivitas ke broker MQTT melalui jaringan Wi-Fi sehingga data dapat ditransmisikan secara ringan dan *real-time*. Broker MQTT kemudian menjadi perantara pengiriman data menuju server aplikasi untuk dilakukan proses penyimpanan dan pengelolaan.

Pada server, data pola gerakan tangan *welder* disimpan ke dalam *database* (MongoDB) sehingga dapat diakses kembali untuk keperluan pemantauan maupun riwayat aktivitas. Data yang telah tersimpan tersebut dibaca oleh sistem *dashboard monitoring* dan ditampilkan pada antarmuka *supervisor* dalam bentuk informasi status aktivitas dan histori aktivitas kerja yang dikenali oleh sistem. Dengan alur ini, *supervisor* dapat memantau kondisi dan aktivitas *welder* secara terpusat, *real-time*, dan terstruktur melalui *dashboard* tanpa perlu berinteraksi langsung dengan perangkat sensor di lapangan.

3.2 Tahapan Penelitian

Tahapan penelitian ini dilakukan secara bertahap seperti yang terlihat pada Gambar 3.5, agar proses perancangan sistem dapat berjalan terstruktur.



Gambar 3.5 Diagram Penelitian
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Tahap pertama adalah identifikasi masalah dan studi literatur, yaitu menganalisis kebutuhan penelitian serta meninjau referensi terkait penggunaan sensor IMU dan metode LSTM pada sistem klasifikasi posisi pengelasan (*welding position*). Tahap berikutnya adalah perumusan tujuan dan spesifikasi sistem, yang digunakan sebagai dasar dalam merancang kebutuhan *hardware* dan *software*.

Selanjutnya dilakukan perancangan sistem *hardware* dan *software*, mencakup desain perangkat *wearable* IMU, konfigurasi ESP32, serta perancangan

alur pemrosesan data. Setelah itu dilakukan pengumpulan data posisi pengelasan 1G, 2G, 3G, dan 4G, diikuti tahap pengolahan data dan pelatihan model LSTM melalui proses *filtering*, segmentasi, dan klasifikasi aktivitas.

Tahap evaluasi dilakukan untuk memastikan performa model telah sesuai dengan target. Jika hasil belum optimal, dilakukan perbaikan hingga memenuhi kriteria. Tahap terakhir adalah implementasi sistem monitoring serta analisis hasil dan penyusunan kesimpulan penelitian.

3.2.1 Identifikasi Masalah

Pada tahap ini dilakukan proses identifikasi terhadap permasalahan yang terjadi pada sektor industri khususnya pada aktivitas kerja *welder* dalam proses konstruksi kapal. Saat ini, proses pemantauan aktivitas *welder* di lapangan masih banyak dilakukan secara manual melalui observasi *visual* oleh *supervisor*, tanpa adanya dukungan perangkat sensor yang mampu merekam pola gerak dan postur tubuh secara objektif. Kondisi tersebut menyebabkan evaluasi kinerja *welder* menjadi kurang akurat, bersifat subjektif, dan sulit digunakan sebagai dasar penilaian kualitas kerja ataupun keselamatan kerja.

Selain itu, aktivitas pengelasan memiliki karakteristik gerakan tangan yang berulang serta dilakukan dalam durasi kerja yang panjang. Hal ini berpotensi menimbulkan kelelahan fisik, kesalahan prosedur, bahkan risiko kecelakaan kerja apabila tidak terpantau dengan baik. Pada kenyataannya, industri masih belum memiliki sistem otomasi yang dapat melakukan perekaman, pelacakan posisi, serta pengenalan aktivitas *welder* secara *real-time* menggunakan teknologi sensor. Data aktivitas kerja yang dihasilkan pun terbatas dan tidak terdokumentasi secara sistematis sehingga menyulitkan proses analisis performa maupun pembinaan kompetensi operator las.

Berdasarkan permasalahan tersebut, diperlukan sebuah solusi berbasis teknologi yang mampu merekam pola gerakan tangan *welder* secara otomatis. Oleh karena itu, pada penelitian ini dikembangkan sistem klasifikasi posisi pengelasan (*welding position*) berbasis *multi-sensor* IMU yang diproses menggunakan metode *deep learning* LSTM, sehingga data gerak yang diperoleh dapat dianalisis secara komputasional dan mendukung evaluasi kerja *welder* secara lebih objektif dan terukur.

3.2.2 Penetapan Tujuan dan Manfaat Penelitian

Berdasarkan permasalahan yang telah dijabarkan pada bagian sebelumnya, penelitian ini menetapkan tujuan dan manfaat yang menjadi arah utama pelaksanaan kajian. Pada saat ini, penelitian mengenai pengenalan aktivitas berbasis *multi-sensor* IMU memang telah banyak dilakukan, namun penerapannya untuk klasifikasi posisi pengelasan (*welding position*) masih relatif terbatas. Selain itu, proses evaluasi aktivitas kerja *welder* di lingkungan industri sebagian besar masih dilakukan secara manual, sehingga informasi mengenai pola gerak dan konsistensi postur kerja belum dapat diperoleh secara objektif dan terstruktur. Kondisi tersebut menunjukkan perlunya pengembangan sistem pengenalan untuk klasifikasi posisi pengelasan (*welding position*) berbasis sensor yang mampu mengolah data gerakan tangan *welder* dalam bentuk sinyal *time-series*.

Rumusan masalah dalam penelitian ini meliputi bagaimana merancang dan mengembangkan sebuah sistem berbasis *embedded system* yang mampu mengumpulkan data pergerakan tubuh *welder* melalui *multi-sensor* IMU secara *real-time*, kemudian mengolah data tersebut menggunakan metode *deep learning Long Short-Term Memory* (LSTM) untuk mengklasifikasikan posisi pengelasan (*welding position*). Berdasarkan rumusan tersebut, tujuan penelitian ini adalah menghasilkan sebuah prototipe sistem klasifikasi posisi pengelasan (*welding position*) yang dapat mengidentifikasi pola gerakan tangan *welder* secara otomatis dan terukur.

Manfaat dari penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan teknologi pemantauan aktivitas kerja di sektor industri, khususnya pada aktivitas pengelasan. Sistem yang dikembangkan diharapkan dapat mendukung proses evaluasi kinerja *welder* secara lebih objektif, membantu pemantauan aktivitas dan pergerakan tubuh secara *real-time*, serta menjadi dasar bagi pengembangan penelitian lanjutan terkait sistem *monitoring* berbasis sensor dan metode *deep learning* pada lingkungan industri maritim.

3.2.3 Studi Literatur

Studi literatur merupakan tahapan pengumpulan, penelaahan, dan analisis berbagai sumber ilmiah yang memiliki keterkaitan dengan topik penelitian. Kegiatan ini dilakukan untuk memperoleh pemahaman yang komprehensif

mengenai konsep dasar, perkembangan teknologi, metode penelitian, serta hasil-hasil studi terdahulu yang relevan dengan pengenalan aktivitas berbasis sensor IMU dan penerapan metode *deep learning* LSTM. Melalui studi literatur, peneliti dapat menyusun landasan teoritis yang kuat sebagai dasar dalam perancangan sistem, pemilihan metode pemrosesan data, serta penentuan komponen perangkat keras dan perangkat lunak yang digunakan pada penelitian ini.

Sumber literatur yang digunakan meliputi jurnal ilmiah bereputasi, prosiding konferensi, e-book, artikel penelitian, serta datasheet komponen sensor dan modul embedded system. Selain itu, beberapa referensi pendukung juga diperoleh dari dokumentasi teknis dan publikasi terkait implementasi sistem pengenalan aktivitas pada lingkungan industri. Dengan adanya studi literatur ini, penelitian Tugas Akhir diharapkan memiliki acuan ilmiah yang jelas, sehingga proses perancangan sistem Klasifikasi posisi pengelasan (*welding position*) berbasis *multi-sensor* IMU dapat dilakukan secara terarah, metodologis, dan sesuai dengan perkembangan teknologi terkini.

3.2.4 Analisis Kebutuhan Sistem

Analisis kebutuhan sistem dilakukan untuk mengidentifikasi dan menentukan seluruh komponen yang diperlukan agar sistem pengenalan aktivitas welder berbasis multi-sensor IMU dan metode *Long Short-Term Memory* (LSTM) dapat berjalan sesuai dengan tujuan penelitian. Rincian kebutuhan komponen dan teknologi yang digunakan dalam penelitian Tugas Akhir ini disajikan pada Tabel 3.1 dibawah ini. Adapun kebutuhan komponen dan teknologi yang diperlukan dalam penelitian Tugas Akhir ini sebagai berikut:

Tabel 3.1 Analisa kebutuhsn sistem


No	Jumlah	Nama Barang
1	1 buah	ESP32
2	1 buah	ICM-20948
3	1 buah	LiPo 3.7V 5000 mAh <i>Battery</i>
4	1 buah	XL6009 <i>Step Up Converter</i>
5	1 buah	<i>Welder Glove</i>

(Sumber : Dokumentasi Pribadi Penulis, 2026).

3.3 Desain dan Perancangan Sistem

Desain dan perancangan sistem dilakukan untuk menentukan kebutuhan perangkat keras dan perangkat lunak yang digunakan dalam pengembangan sistem klasifikasi posisi pengelasan berbasis *multi-sensor Inertial Measurement Unit* (IMU) dan metode *Long Short-Term Memory* (LSTM). Perancangan sistem meliputi **hardware elektrik, hardware mekanik, serta desain UI/UX** yang saling terintegrasi untuk mendukung proses akuisisi data, klasifikasi, dan monitoring aktivitas pengelasan secara *real-time*.

3.3.1 Hardware Electric



Gambar 3.6 Perancangan *Hardware Electric*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Perangkat keras kelistrikan pada sistem ini dirancang untuk mendukung proses akuisisi data gerakan tangan *welder* secara *real-time* serta pengiriman data secara nirkabel seperti yang dapat dilihat pada Gambar 3.6 diatas. Komponen utama yang digunakan meliputi modul *Inertial Measurement Unit* (IMU) ICM-20948, mikrokontroler ESP32, sumber daya baterai Li-Po 3.7 V, DC-DC converter, serta *power button* (PB switch) sebagai pengendali daya sistem. Seluruh komponen diintegrasikan dalam satu rangkaian portabel yang memungkinkan sistem digunakan sebagai perangkat wearable selama aktivitas pengelasan berlangsung.

Modul IMU ICM-20948 berfungsi sebagai sensor utama untuk merekam pergerakan tangan *welder*. Sensor ini mengintegrasikan *accelerometer, gyroscope,*

dan *magnetometer* dalam satu modul, sehingga mampu mengukur percepatan linier, kecepatan sudut, serta orientasi terhadap medan magnet bumi. Data sensor dari IMU dikirimkan ke mikrokontroler ESP32 melalui komunikasi digital (I²C/SPI) untuk diproses lebih lanjut. ESP32 dipilih karena memiliki kemampuan pemrosesan yang cukup tinggi serta telah dilengkapi modul Wi-Fi internal, sehingga mendukung transmisi data sensor secara real-time ke server tanpa memerlukan perangkat tambahan.

Sistem catu daya menggunakan baterai Li-Po 3.7 V berkapasitas 5000 mAh sebagai sumber energi utama agar perangkat dapat beroperasi secara mandiri dan portabel. Tegangan keluaran baterai kemudian diatur menggunakan DC-DC converter untuk menyesuaikan kebutuhan tegangan kerja ESP32 dan modul IMU agar sistem tetap stabil dan aman. *Power button* (PB switch) digunakan sebagai saklar utama untuk menghidupkan dan mematikan sistem, sehingga memudahkan pengoperasian di lapangan. Dengan konfigurasi hardware electrical ini, sistem mampu bekerja secara stabil, hemat daya, dan sesuai untuk penggunaan wearable pada lingkungan kerja pengelasan yang dinamis.

3.3.2 Hardware Mekanik



Gambar 3.7 Perancangan *Hardware Mekanik*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Perancangan hardware mekanik pada penelitian ini mengintegrasikan sistem sensor secara langsung pada *welder glove*, dengan posisi pemasangan berada di lengan bawah bagian luar (*outer forearm*) dan terletak sedikit ke atas dari pergelangan tangan, sebagaimana ditunjukkan pada Gambar 3.7 diatas. Posisi ini

dipilih karena tidak mengganggu gengaman tangan saat mengelas, tetap mengikuti pergerakan lengan, serta mampu merekam pola gerakan tangan welder secara stabil pada berbagai posisi pengelasan (1G–4G).

Unit sensor yang terdiri dari multi-sensor IMU, ESP32, baterai Li-Po 5000 mAh, push button, dan LED indikator ditempatkan di dalam kantong (*pouch*) khusus yang menyatu dengan welder glove. Kantong sensor berbentuk persegi panjang dan menempel langsung pada permukaan luar glove, dengan bagian depan dilengkapi penutup berlapis (*flap*) dan resleting (*zipper*) sebagai akses utama ke komponen elektronik. Desain ini memungkinkan sensor terlindungi dengan baik sekaligus tetap mudah diakses.

Material kantong sensor menggunakan bahan tahan panas dan percikan api, sejenis kulit atau kain khusus pengelasan, yang sesuai dengan material *welder glove* pada umumnya. Lapisan ini berfungsi untuk melindungi sistem elektronik dari paparan panas, percikan las, dan debu logam selama proses pengelasan. Penggunaan *zipper* memungkinkan *welder* membuka kantong untuk mengambil atau mengisi ulang baterai tanpa perlu melepas *glove*, sehingga mendukung aspek kepraktisan dan keselamatan kerja selama penggunaan sistem sensor.


3.3.3 Perancangan Desain UI/UX

Perancangan UI/UX pada sistem monitoring welding glove difokuskan pada penyajian informasi hasil klasifikasi posisi pengelasan secara real-time serta kemudahan pengawasan oleh supervisor.



Gambar 3.8 Halaman Login dan Register *Dashboard*
(Sumber: Dokumentasi Pribadi Penulis, 2026)


Laman login dan register pada *Welding Monitoring System* pada Gambar 3.8 berfungsi sebagai mekanisme autentikasi untuk membatasi akses sistem hanya kepada pengguna yang berwenang, khususnya supervisor. Pada halaman ini, supervisor melakukan proses login dengan memasukkan email dan password yang telah terdaftar, kemudian sistem akan memverifikasi kredensial sebelum mengizinkan akses ke dashboard utama. Selain itu, tersedia fitur registrasi akun melalui menu *create account* untuk memungkinkan penambahan supervisor baru secara terkontrol. Keberadaan laman ini bertujuan untuk menjaga keamanan sistem serta melindungi data monitoring pengelasan, jadwal kerja welder, dan informasi peringatan agar hanya dapat diakses dan dikelola oleh pihak yang memiliki otoritas.



Gambar 3.9 *Dashboard Monitoring*
(Sumber: Dokumentasi Pribadi Penulis, 2026)


Gambar 3.9 menunjukkan tampilan dashboard utama *Welding Monitoring System* yang digunakan oleh supervisor untuk memantau aktivitas pengelasan secara real-time. Pada dashboard ini ditampilkan ringkasan kondisi sistem berupa jumlah welding glove aktif, jumlah welder yang bekerja, kondisi normal, dan jumlah peringatan, serta kartu monitoring untuk setiap welding glove (G01–G04) yang memuat identitas welder, hasil klasifikasi posisi pengelasan menggunakan metode LSTM, dan posisi pengelasan yang diizinkan sesuai jadwal kerja harian. Apabila sistem mendeteksi welder melakukan posisi pengelasan di luar jadwal yang telah ditetapkan, dashboard akan menampilkan indikator peringatan dan notifikasi

sebagai *early warning*, sehingga supervisor dapat segera memberikan teguran atau instruksi langsung kepada welder di lapangan.



Gambar 3.10 *Welder's Schedule*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 3.10 menampilkan *interface* fitur *Daily Welder's Schedule* pada *Welding Monitoring System* yang digunakan oleh supervisor untuk mengatur jadwal kerja serta menentukan posisi pengelasan yang diperbolehkan bagi setiap *welder* atau sarung tangan *welder* pada tanggal tertentu. Melalui tampilan ini, *supervisor* dapat memilih *welder* yang akan diatur, kemudian menentukan posisi pengelasan yang diizinkan, yaitu 1G (flat), 2G (horizontal), 3G (vertical), dan 4G (overhead), sesuai dengan kebutuhan operasional dan standar keselamatan kerja. Posisi pengelasan yang dipilih akan ditampilkan kembali pada bagian ringkasan sebagai bentuk konfirmasi sebelum pengaturan disimpan ke dalam sistem, sehingga meminimalkan kesalahan dalam penjadwalan. Pengaturan jadwal ini selanjutnya digunakan sebagai acuan dalam proses monitoring aktivitas pengelasan secara *real-time*, di mana hasil klasifikasi posisi pengelasan dari sensor IMU dibandingkan dengan jadwal yang telah ditetapkan untuk memastikan aktivitas welder dilakukan sesuai dengan aturan yang berlaku. Dengan adanya fitur ini, *supervisor* dapat melakukan pengawasan aktivitas pengelasan secara lebih terstruktur serta mendukung penerapan disiplin kerja dan kepatuhan terhadap prosedur operasional yang telah ditentukan.




Gambar 3.11 *History* Posisi Pengelasan
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 3.11 menampilkan history posisi pengelasan pada *Welding Monitoring System* yang merekam urutan aktivitas pengelasan welder berdasarkan hasil klasifikasi sensor IMU. Pada tampilan ini ditunjukkan informasi ringkasan aktivitas, meliputi jumlah total aktivitas pengelasan, jumlah aktivitas dengan status normal, jumlah aktivitas yang menghasilkan peringatan, serta total durasi pengelasan dalam satu periode pemantauan. Riwayat aktivitas disajikan dalam bentuk linimasa yang memuat waktu pelaksanaan, posisi pengelasan yang terdeteksi (1G, 2G, 3G, dan 4G), durasi setiap aktivitas, serta status kesesuaian terhadap posisi yang diizinkan. Aktivitas pengelasan yang sesuai dengan jadwal ditandai dengan status *Normal*, sedangkan aktivitas dengan posisi yang tidak diizinkan ditandai dengan status *Warning* disertai keterangan pelanggaran. Riwayat posisi pengelasan ini digunakan sebagai bahan evaluasi untuk memantau kepatuhan welder terhadap aturan yang telah ditetapkan serta mendukung proses pengawasan aktivitas pengelasan secara berkelanjutan.

3.3.4 Perancangan Metode LSTM

Metode *Long Short-Term Memory* (LSTM) pada penelitian ini digunakan untuk mengenali posisi pengelasan berdasarkan data *time-series* yang diperoleh dari *multi-sensor Inertial Measurment Unit* (IMU). *Multi-sensor* IMU yang digunakan terdiri dari *accelerometer* (ACC), *gyroscope* (GYRO), dan *magnetometer* (MAG),

yang masing-masing berfungsi untuk mengukur percepatan, kecepatan sudut, dan orientasi. Data dari ketiga sensor tersebut dikumpulkan secara berurutan dan dijadikan sebagai input layer dalam bentuk sequence data, sehingga perubahan gerakan dan orientasi *welder* selama proses pengelasan dapat direpresentasikan secara temporal.



Gambar 3.12 Arsitektur Model LSTM
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Arsitektur LSTM yang dirancang terdiri dari dua lapisan LSTM bertingkat (*stacked LSTM*) seperti yang terlihat pada Gambar 3.12 di atas. Lapisan LSTM pertama berfungsi untuk mengekstraksi fitur temporal dasar dari data *multi-sensor* IMU, seperti pola perubahan gerakan dan orientasi tangan *welder*. Selanjutnya, keluaran dari lapisan ini diproses oleh lapisan LSTM kedua untuk mempelajari pola temporal tingkat tinggi yang lebih kompleks, sehingga sistem mampu membedakan karakteristik gerakan pada setiap posisi pengelasan secara lebih akurat.

Keluaran dari lapisan LSTM kemudian diteruskan ke *Fully Connected Layer* dengan fungsi aktivasi *Rectified Linear Unit* (ReLU) untuk mengolah hasil ekstraksi fitur menjadi representasi yang lebih informatif sebelum dilakukan klasifikasi. Pada tahap akhir, digunakan *output layer* dengan fungsi aktivasi

Softmax untuk menghasilkan probabilitas dari setiap kelas posisi pengelasan. Sistem ini mengklasifikasikan posisi pengelasan ke dalam empat kelas, yaitu posisi pengelasan 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*). Kelas dengan nilai probabilitas tertinggi dipilih sebagai hasil prediksi posisi pengelasan yang sedang dilakukan oleh *welder*. Dengan memanfaatkan kemampuan LSTM dalam mempelajari ketergantungan temporal jangka pendek dan jangka panjang, metode ini diharapkan mampu memberikan hasil klasifikasi posisi pengelasan yang akurat dan stabil.

Mengingat model LSTM memiliki jumlah parameter yang relatif besar dan berpotensi mengalami *overfitting*, pada perancangan arsitektur ini diterapkan strategi mitigasi berupa penggunaan *dropout layer* pada jaringan LSTM. Penerapan dropout bertujuan untuk mengurangi ketergantungan model terhadap neuron tertentu selama proses pelatihan sehingga mampu meningkatkan kemampuan generalisasi model terhadap data baru. Penelitian yang dilakukan oleh Verianto menunjukkan bahwa penggunaan dropout pada arsitektur LSTM efektif dalam menurunkan selisih performa antara data pelatihan dan data validasi, sehingga model menjadi lebih stabil dan tidak mudah mengalami *overfitting* pada data *time-series* (Verianto, 2024).

Selain itu, perancangan arsitektur LSTM yang tepat serta pengaturan proses pelatihan yang sesuai berperan penting dalam menghasilkan performa klasifikasi yang konsisten dan andal pada data sekuensial, khususnya ketika diterapkan pada kondisi data yang bervariasi (Saputra et al., 2025). Dengan demikian, penerapan dropout pada arsitektur LSTM dalam penelitian ini diharapkan mampu menghasilkan klasifikasi posisi pengelasan yang akurat, stabil, dan dapat digeneralisasikan pada lingkungan industri pengelasan.

3.4 Skema Pengumpulan Data

Skema pengumpulan data dilakukan untuk memperoleh data pergerakan tangan welder pada setiap posisi pengelasan menggunakan sensor ICM-20948 yang terintegrasi dengan ESP32. Data dikumpulkan secara *real-time* pada empat posisi pengelasan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*), kemudian dikirimkan ke sistem untuk disimpan dan digunakan sebagai dataset dalam proses pelatihan serta pengujian model LSTM.

3.4.1 Objek dan Perangkat Pengumpulan Data

Objek penelitian pada pengambilan data ini adalah pola pergerakan tangan welder selama melakukan aktivitas pengelasan. Gerakan tangan dipilih sebagai objek utama karena secara langsung berkaitan dengan teknik pengelasan, arah gerak elektroda, serta orientasi kerja pada setiap posisi pengelasan. Perbedaan posisi pengelasan akan menghasilkan perbedaan karakteristik gerakan tangan yang dapat diidentifikasi melalui data sensor. Pengambilan data dilakukan dengan melibatkan empat orang *welder* sebagai subjek uji coba, guna memperoleh variasi pola gerakan tangan yang representatif.

Posisi pengelasan yang diamati dalam penelitian ini meliputi 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*). Keempat posisi tersebut merupakan posisi standar dalam industri pengelasan dan memiliki tingkat kesulitan serta orientasi kerja yang berbeda. Dengan mengamati seluruh posisi tersebut, sistem diharapkan mampu mempelajari variasi pola gerakan tangan *welder* secara menyeluruh.

Perangkat pengumpulan data yang digunakan adalah modul IMU 9-DoF yang terdiri dari sensor *accelerometer*, *gyroscope*, dan *magnetometer*, yang akan langsung dipasang pada sarung tangan *welder* (*welder glove*). Sensor IMU yang terpasang pada *welder glove* dihubungkan dengan mikrokontroler ESP32 sebagai pengolah data awal dan perangkat komunikasi nirkabel. ESP32 bertugas membaca data sensor secara *real-time* dan mengirimkannya ke server melalui jaringan Wi-Fi menggunakan protokol MQTT, sehingga proses pengumpulan data dapat dilakukan secara efisien dan berkelanjutan selama aktivitas pengelasan berlangsung.

3.4.2 Jenis dan Jumlah Data yang Dikumpulkan

Jenis data yang dikumpulkan dalam penelitian ini berupa data numerik *time-series* yang dihasilkan oleh sensor IMU selama aktivitas pengelasan berlangsung. Data *time-series* dipilih karena mampu merepresentasikan perubahan gerakan tangan *welder* secara berurutan berdasarkan waktu, yang sangat penting untuk analisis pola gerakan.

Data *accelerometer* digunakan untuk merekam nilai percepatan linier pada sumbu X, Y, dan Z. Data ini mencerminkan intensitas dan arah pergerakan tangan *welder* selama proses pengelasan. Sementara itu, data *gyroscope* merekam

kecepatan sudut atau rotasi tangan pada ketiga sumbu, sehingga dapat menggambarkan perubahan orientasi tangan pada setiap posisi pengelasan. Data *magnetometer* digunakan sebagai referensi orientasi terhadap medan magnet bumi untuk menjaga kestabilan dan konsistensi pembacaan arah gerakan.

Pengambilan data dilakukan dengan frekuensi *sampling* sebesar 50 Hz, yang berarti sensor IMU menghasilkan 50 sampel data setiap detik pada masing-masing sumbu sensor. Dengan frekuensi ini, sistem mampu merekam perubahan gerakan tangan welder secara detail dan responsif sehingga karakteristik gerakan pada setiap posisi pengelasan dapat terekam dengan baik. Data yang dihasilkan bersifat kuantitatif dan berurutan, sehingga sesuai digunakan sebagai *input* pada metode *Long Short-Term Memory* (LSTM).

Data yang dikumpulkan bersifat berlabel sesuai dengan posisi pengelasan yang dilakukan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*). Untuk setiap posisi pengelasan, data direkam selama kurang lebih 1–2 menit atau hingga elektroda pengelasan habis digunakan. Dengan frekuensi *sampling* sebesar 50 Hz, sensor IMU menghasilkan 50 sampel data setiap detik. Pengambilan data dilakukan selama 1–2 menit untuk setiap posisi pengelasan, sehingga jumlah data yang dihasilkan berkisar antara 3.000 hingga 6.000 sampel. Jumlah tersebut diperoleh dari hasil perkalian antara frekuensi *sampling* (50 sampel/detik) dengan durasi pengambilan data (60–120 detik). Rentang jumlah data ini disesuaikan dengan durasi aktual proses pengelasan, sehingga data yang dikumpulkan tetap merepresentasikan kondisi nyata di lapangan dan bersifat cukup representatif untuk digunakan dalam proses pelatihan, validasi, dan pengujian model LSTM.

3.4.3 Skenario dan Durasi Pengambilan Data

Durasi pengambilan data pada penelitian ini ditentukan berdasarkan waktu aktual proses pengelasan. Untuk setiap posisi pengelasan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*), pengambilan data dilakukan selama kurang lebih 1-2 menit atau hingga elektroda pengelasan habis digunakan. Pendekatan ini dipilih agar data yang dikumpulkan merepresentasikan satu siklus kerja pengelasan yang utuh dan realistis.

Selama, durasi tersebut, sensor IMU yang terpasang pada *welder glove* akan merekam pergerakan tangan *welder* secara kontinu dan *real-time*. Data yang

dihasilkan mencakup variasi gerakan tangan selama proses penyalaan awal, pergerakan stabil saat pengelasan berlangsung, hingga proses ketika elektroda habis. Dengan demikian, dataset yang diperoleh tidak hanya merekam gerakan statis, tetapi juga dinamika gerakan tangan secara menyeluruh.

Pengambilan data dilakukan secara berulang pada setiap posisi pengelasan untuk memastikan ketersediaan data yang cukup dan seimbang antar kelas. Durasi 1-2 menit per posisi dianggap memadai untuk menghasilkan data *time-series* yang kaya pola dan relevan untuk proses pelatihan serta evaluasi model LSTM dalam mengklasifikasikan posisi pengelasan.

3.4.4 Periode Pengambilan Data

Pengambilan data pada penelitian ini tidak dilakukan dalam satu hari, melainkan dilaksanakan secara bertahap dalam beberapa periode waktu. Pendekatan ini dipilih untuk memastikan bahwa data yang dikumpulkan mempresentasikan kondisi kerja *welder* yang realistis serta mengurangi potensi bias akibat faktor kelelahan, kondisi lingkungan, dan keterbatasan operasional di lapangan.

Pelaksanaan pengambilan data mempertimbangkan kondisi lingkungan kerja *welder*, seperti jadwal pekerjaan pengelasan, tingkat aktivitas di area kerja, serta faktor keselamatan dan kenyamanan kerja. Selain itu, kesiapan peralatan penelitian, termasuk sensor IMU, mikrokontroler ESP32, serta sistem komunikasi dan penyimpanan data, juga menjadi pertimbangan utama sebelum setiap sesi pengambilan data dilakukan. Dengan demikian, setiap proses pengambilan data dapat berjalan secara optimal dan stabil.

Melalui pengambilan data yang dilakukan secara bertahap, penelitian ini diharapkan mampu menghasilkan dataset yang lebih variatif, konsisten, dan reliabel. Data yang dikumpulkan pada periode yang berbeda memungkinkan sistem untuk menangkap variasi alami pergerakan tangan *welder* yang dipengaruhi oleh kondisi kerja harian, sehingga model klasifikasi berbasis LSTM dikembangkan memiliki kemampuan generalisasi yang lebih baik ketika diterapkan pada lingkungan industri nyata.

3.5 Skema Pengujian

Skema pengujian pada penelitian ini dirancang untuk mengevaluasi kinerja sistem kasifikasi posisi pengelasan berbasis *multi-sensor* IMU dan metode *deep learning* LSTM. Pengujian dilakukan untuk memastikan bahwa sistem mampu merekam, memproses, dan mengklasifikasikan posisi pengelasan secara akurat dan konsisten berdasarkan pola pergerakan tangan *welder* selama proses pengelasan berlangsung.

Tahapan pengujian diawali dengan proses pengumpulan data pergerakan tangan *welder* menggunakan sensor IMU yang terpasang pada *welder glove*. Data yang diperoleh kemudian melalui tahap *pre-processing*, meliputi pembersihan data, normalisasi, dan segmentasi *time-series* menggunakan metode *windowing*. Data hasil *pre-processing* selanjutnya digunakan sebagai *input* pada model LSTM yang telah dilatih untuk melakukan klasifikasi posisi pengelasan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*).

Pengujian sistem dilakukan dengan membandingkan hasil klasifikasi model terhadap label posisi pengelasan yang telah ditentukan sebelumnya. Evaluasi kinerja sistem dilakukan menggunakan beberapa parameter pengujian, seperti tingkat akurasi, *precision*, *recall*, dan F1-score. Selain itu, pengujian juga mencakup analisis konsistensi hasil klasifikasi pada berbagai sesi pengambilan data untuk menilai reliabilitas sistem dalam kondisi kerja yang berbeda. Hasil pengujian ini digunakan sebagai dasar untuk menilai kelayakan sistem dalam mendukung evaluasi aktivitas dan keterampilan *welder* di lingkungan industri maritim.

BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini membahas hasil dari pengujian tugas akhir beserta analisisnya. Pengujian dilakukan dalam beberapa bagian seperti pengujian hardware, pengujian Software, serta pengujian sistem. Hal ini dilakukan untuk memastikan bahwa Seluruh sistem yang terdapat pada tugas akhir ini mampu berjalan dengan baik Sesuai dengan perencanaan sebelumnya.

4.1 Perancangan *Hardware*

Pada tahap ini dilakukan implementasi sistem yang telah dirancang pada BAB III. Sistem yang dikembangkan merupakan wearable device berupa sarung tangan welder yang dilengkapi dengan sensor IMU dan mikrokontroler ESP32 untuk mengakuisisi data gerakan tangan secara real-time.


4.1.1 Perancangan Hardware Mikrokontroler ESP32

Mikrokontroler yang digunakan pada penelitian ini berupa *printed circuit board* (PCB) berbasis ESP32-WROOM-32 yang dirancang dan dibuat secara mandiri oleh peneliti menggunakan software Autodesk Eagle. Perancangan PCB ini difokuskan pada pembuatan board mikrokontroler utama yang berfungsi sebagai pusat kendali sistem. Tahapan perancangan diawali dengan menentukan konfigurasi pin input dan output pada ESP32 yang akan digunakan, termasuk pin untuk komunikasi data, catu daya, serta kebutuhan pemrograman. Selanjutnya, peneliti membuat skematik rangkaian menggunakan *software* Eagle dengan menambahkan komponen-komponen pendukung seperti rangkaian regulator, tombol *reset* dan *boot*, serta header pin untuk koneksi eksternal.

Setelah skematik selesai, tahap berikutnya adalah pembuatan layout PCB dengan mengatur posisi komponen dan melakukan routing jalur koneksi antar pin. Proses ini dilakukan dengan mempertimbangkan efisiensi tata letak serta kemudahan dalam proses fabrikasi dan perakitan. Jalur catu daya juga dirancang secara khusus untuk memastikan distribusi tegangan yang stabil pada seluruh bagian rangkaian. Desain PCB kemudian dilakukan pengecekan menggunakan fitur *Electrical Rule Check* (ERC) dan *Design Rule Check* (DRC) untuk memastikan tidak terdapat kesalahan koneksi maupun pelanggaran aturan desain. Setelah

dinyatakan sesuai, desain diekspor ke dalam format file Gerber yang digunakan sebagai acuan dalam proses pencetakan PCB.

Hasil perakitan dan pencetakan PCB ESP32 dapat dilihat pada Gambar 4.1 dan Gambar 4.2 di bawah ini :



Gambar 4.1 Design Board ESP32
(Sumber: Dokumentasi Pribadi Penulis, 2026)




Gambar 4.2 Board ESP32
(Sumber: Dokumentasi Pribadi Penulis, 2026)

4.1.2 Perancangan *Board PCB Integrasi*


Perancangan board PCB integrasi dilakukan untuk menyatukan seluruh komponen utama sistem ke dalam satu media yang lebih ringkas, rapi, dan mudah digunakan. Board PCB ini dirancang sebagai tempat integrasi antara mikrokontroler ESP32, sensor IMU ICM-20948, modul charger baterai, serta jalur catu daya. Dengan menggunakan PCB integrasi, koneksi antar komponen menjadi lebih stabil dibandingkan penggunaan kabel jumper secara langsung, sehingga dapat mengurangi noise maupun kesalahan pembacaan data sensor.

Gambar 4.3 di bawah menunjukkan hasil perancangan layout PCB integrasi menggunakan software Autodesk EAGLE. Pada desain tersebut terlihat jalur koneksi antar komponen, posisi pemasangan sensor IMU, modul charger baterai, serta socket ESP32 yang telah disusun sesuai kebutuhan sistem. Selain itu, desain PCB juga dilengkapi jalur catu daya dan ground plane untuk membantu menjaga kestabilan distribusi tegangan pada sistem.



Gambar 4.3 *Design Board Integrasi*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Setelah proses desain selesai, PCB dicetak dan dilakukan proses perakitan komponen. Tahap perakitan meliputi pemasangan header pin, ESP32, sensor IMU, modul charger baterai, serta pengkabelan antar komponen. Seluruh komponen dipasang sesuai dengan layout yang telah dirancang sebelumnya agar koneksi antar modul dapat berjalan dengan baik.



Gambar 4.4 *Board Integrasi*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.4 di atas menunjukkan hasil implementasi board PCB integrasi yang telah selesai dirakit. Berdasarkan hasil pengujian awal, board mampu menyalakan sistem dengan baik dan seluruh komponen dapat bekerja secara normal. Integrasi komponen ke dalam satu board PCB juga membuat perangkat menjadi lebih portable, rapi, dan mempermudah proses pengujian maupun pengembangan sistem selanjutnya.

4.2 Hasil Perancangan Mekanik

Perancangan mekanik pada penelitian ini dilakukan untuk menyediakan media pemasangan sensor dan perangkat elektronik yang nyaman digunakan saat proses pengambilan data gerakan. Desain mekanik dibuat menggunakan sarung tangan keselamatan (safety glove) yang dimodifikasi sebagai media pemasangan sensor IMU ICM-20948 dan board PCB integrasi yang berisi mikrokontroler ESP32 beserta rangkaian pendukung lainnya.

Pada tahap perancangan, sensor IMU ICM-20948 ditempatkan pada bagian punggung tangan dengan mempertimbangkan kestabilan posisi sensor selama pengujian. Penempatan tersebut bertujuan agar sensor dapat mendeteksi perubahan orientasi dan gerakan tangan secara optimal tanpa mengganggu kenyamanan

pengguna. Selain itu, board PCB integrasi yang berisi mikrokontroler ESP32 dan rangkaian pendukung lainnya juga dipasang pada bagian punggung tangan untuk mempermudah proses pengkabelan dan mengurangi kemungkinan terjadinya pergeseran posisi komponen saat digunakan.



Gambar 4.5 Rancangan Mekanik
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.5 di atas menunjukkan hasil implementasi mekanik yang telah dirancang. Pada gambar tersebut terlihat bahwa sensor IMU dan board PCB integrasi telah terpasang secara temporal pada sarung tangan. Kabel penghubung sensor juga disusun sedemikian rupa sehingga tidak menghambat pergerakan tangan pengguna selama proses pengambilan data. Dengan adanya perancangan mekanik ini, seluruh komponen elektronik dapat terintegrasi dalam satu perangkat yang mudah digunakan, portabel, dan nyaman saat dikenakan. Selain meningkatkan kerapihan sistem, desain mekanik yang dibuat juga mampu menjaga posisi sensor tetap stabil selama pengujian sehingga kualitas data yang diperoleh menjadi lebih konsisten dan dapat digunakan untuk proses analisis selanjutnya.

4.3 Hasil Pengujian Parsial Sensor

Pengujian parsial sensor dilakukan untuk mengetahui tingkat akurasi sensor IMU yang digunakan pada penelitian ini. Sensor yang digunakan adalah sensor IMU ICM-20948 yang berfungsi untuk mengukur percepatan (accelerometer), kecepatan sudut (gyroscope), dan medan magnet (magnetometer). Untuk memvalidasi hasil pembacaan sensor, digunakan sensor IMU pada smartphone iPhone 13 Mini sebagai data acuan.

Pemilihan iPhone 13 Mini sebagai sensor pembanding didasarkan pada kualitas sensor dan sistem kalibrasi yang telah terintegrasi dengan baik pada perangkat tersebut. Sensor IMU pada smartphone telah banyak digunakan dalam berbagai aplikasi navigasi, orientasi perangkat, dan motion sensing sehingga dapat digunakan sebagai referensi dalam proses pengujian. Gambar 4.6 menunjukkan spesifikasi dari iPhone 13 mini sebagai perangkat data acuan.

FITUR	
OS (Saat Rilis)	iOS 15
Jaminan Update	
Sensor	["Accelerometer","Gyro","Proximity","Compass","Barometer","Ultra Wideband (UWB)","Siri natural language commands and dictation"]
Jack 3.5mm	Tidak Ada
Warna	Starlight, Midnight, Blue, Pink, Red
Fitur Lainnya	Speaker Stereo

Gambar 4.6 Spesifikasi Perangkat Data Acuan
(Sumber: <https://carisinyal.com/hp/apple-iphone-13-mini/>)

Berdasarkan spesifikasi tersebut, iPhone 13 Mini memiliki sensor yang mampu mengukur percepatan, kecepatan sudut, dan medan magnet sehingga dapat digunakan sebagai pembanding untuk mengevaluasi kinerja sensor ICM-20948. Pengujian dilakukan dengan menempatkan sensor ICM-20948 dan iPhone 13 Mini pada posisi yang sama, kemudian dilakukan pengambilan data pada beberapa variasi posisi pengujian.

$$Error \% = \frac{Data\ Sensor\ ICM-20948 - Data\ Sensor\ iPhone\ 13\ Mini}{Data\ Sensor\ iPhone\ 13\ Mini} \times 100 \quad (4.1)$$

Nilai error yang diperoleh digunakan sebagai parameter untuk menilai tingkat kesesuaian hasil pembacaan sensor ICM-20948 terhadap sensor referensi. Semakin kecil nilai error yang dihasilkan, maka semakin baik tingkat akurasi sensor yang digunakan dalam penelitian ini.


Sebelum dilakukan pengujian, sensor IMU ICM-20948 terlebih dahulu dihubungkan dengan mikrokontroler ESP32 menggunakan protokol komunikasi Inter-Integrated Circuit (I2C). Konfigurasi koneksi antara sensor dan mikrokontroler ditunjukkan pada Tabel 4.1.

Tabel 4.1 Konektivitas ESP32 dengan ICM-20948

Pin Sensor	Pin ESP32
VCC	3.3V
SCL	IO 22
SDA	IO 21
NCS	3.3V
ADO	3.3V
GND	GND

(Sumber : Dokumentasi Pribadi Penulis,2026).

Konfigurasi koneksi antara ESP32 dan sensor ICM-20948 pada Tabel 4.1 kemudian direalisasikan dalam bentuk rangkaian pengkabelan seperti yang ditunjukkan pada Gambar 4.7. Sensor dihubungkan ke mikrokontroler menggunakan antarmuka Inter-Integrated Circuit (I2C), dengan pin SCL sensor terhubung ke GPIO 22 ESP32 dan pin SDA terhubung ke GPIO 21. Pin VCC dihubungkan ke sumber tegangan 3,3 V, sedangkan pin GND dihubungkan ke ground. Selain itu, pin NCS dan ADO juga dihubungkan ke tegangan 3,3 V untuk mengatur mode operasi sensor agar menggunakan komunikasi I2C.




Gambar 4.7 Wiring ESP32 dengan ICM-20948
(Sumber: Dokumentasi Pribadi Penulis, 2026)

4.3.1 Hasil Pengujian Parsial Sensor Accelerometer

Pengujian parsial sensor accelerometer yang dilakukan seperti yang ditunjukkan pada Gambar 4.8 dilakukan untuk mengetahui kemampuan sensor accelerometer pada modul IMU ICM-20948 dalam mendeteksi percepatan pada masing-masing sumbu pengukuran, yaitu sumbu X, Y, dan Z. Pengujian ini

bertujuan untuk memastikan bahwa sensor dapat menghasilkan data yang sesuai sebelum digunakan pada tahap pengujian dan pengolahan data selanjutnya.



Gambar 4.8 Pengujian Parsial Sensor Accelerometer
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Pada penelitian ini, hasil pembacaan sensor accelerometer ICM-20948 dibandingkan dengan hasil pembacaan sensor accelerometer yang terdapat pada iPhone 13 Mini sebagai data acuan. Pengambilan data dilakukan dengan menempatkan kedua perangkat pada orientasi yang sama sehingga nilai percepatan yang diperoleh dapat dibandingkan secara langsung. Data yang diamati meliputi nilai percepatan pada sumbu X, Y, dan Z yang dihasilkan oleh kedua sensor. Selanjutnya, tingkat kesesuaian data antara sensor ICM-20948 dan sensor referensi dihitung menggunakan persentase error berdasarkan persamaan rumus (4.1). Perhitungan error dilakukan untuk mengetahui seberapa besar selisih pembacaan sensor ICM-20948 terhadap sensor referensi.

Hasil pengujian sensor accelerometer pada masing-masing sumbu kemudian disajikan pada Tabel 4.2, Tabel 4.3, dan Tabel 4.4 di bawah. Data yang diperoleh digunakan untuk mengevaluasi tingkat akurasi sensor ICM-20948 dalam mengukur percepatan pada ketiga sumbu pengukuran, yaitu sumbu X, Y, dan Z. Pengujian dilakukan dengan membandingkan hasil pembacaan sensor terhadap sensor referensi sehingga dapat diketahui tingkat kesesuaian hasil pengukuran. Semakin kecil nilai *error* yang diperoleh, maka semakin baik tingkat akurasi pembacaan sensor, sehingga sensor ICM-20948 layak digunakan sebagai sumber data pada penelitian ini.

Tabel 4.2 Hasil Uji Sensor Accelerometer pada Sumbu X

NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0221	0,0111	0,99%
2	0,0607	0,0561	0,081%
3	0,1038	0,1837	0,43%
4	0,0392	0,0500	0,21%
5	0,0374	0,0456	0,17%
6	0,0542	0,0698	0,22%
7	0,0087	0,0064	0,35%
8	0,0853	0,0571	0,49%
9	0,0248	0,0313	0,20%
10	0,0464	0,0164	1,82%
Rata-rata Error			0,49%

(Sumber : Dokumentasi Pribadi Penulis,2026).

Tabel 4.3 Hasil Uji Sensor Accelerometer pada Sumbu Y

NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0101	0,0174	0,41%
2	0,0461	0,1254	0,52%
3	0,0772	0,0627	0,23%
4	0,0413	0,0806	0,48%
5	0,0532	0,0451	0,17%
6	0,0951	0,0353	1,69%
7	0,0556	0,0247	1,25%
8	0,0269	0,0167	0,61%
9	0,0389	0,0239	0,62%
10	0,0449	0,0289	0,55%
Rata-rata Error			0,65%

(Sumber : Dokumentasi Pribadi Penulis,2026)


Tabel 4.4 Hasil Uji Sensor Accelerometer pada Sumbu X

NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0383	0,0489	0,21%
2	0,0574	0,0304	0,88%
3	0,0861	0,0774	0,11%
4	0,0119	0,0263	0,54%
5	0,0071	0,0027	1,62%
6	0,0527	0,0332	0,58%
7	0,0671	0,0506	0,32%
8	0,0551	0,0392	0,39%
9	0,0191	0,0247	0,22%
10	0,0095	0,0064	0,48%
Rata-rata Error			0,53%

(Sumber : Dokumentasi Pribadi Penulis,2026).

4.3.2 Hasil Pengujian Parsial Sensor Gyroscope

Pengujian parsial sensor gyroscope seperti pada Gambar 4.9 di bawah dilakukan untuk mengetahui kemampuan sensor gyroscope pada modul IMU ICM-20948 dalam mengukur kecepatan sudut (angular velocity) pada masing-masing sumbu pengukuran, yaitu sumbu X, Y, dan Z. Pengujian ini bertujuan untuk mengevaluasi tingkat akurasi sensor sebelum digunakan pada proses pengambilan data gerakan dan pengolahan data lebih lanjut.



Gambar 4.9 Pengujian Parsial Sensor Gyroscope
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Pada penelitian ini, hasil pembacaan sensor gyroscope ICM-20948 dibandingkan dengan hasil pembacaan sensor gyroscope yang terdapat pada iPhone 13 Mini sebagai data acuan. Pengambilan data dilakukan dengan memberikan gerakan rotasi pada perangkat dan sensor secara bersamaan sehingga kedua sensor mengalami kondisi pengukuran yang sama. Data yang diamati berupa nilai kecepatan sudut pada sumbu X, Y, dan Z yang dihasilkan oleh kedua perangkat. Selanjutnya, tingkat kesesuaian data antara sensor ICM-20948 dan sensor referensi dihitung menggunakan persentase error berdasarkan persamaan rumus (4.1). Perhitungan error dilakukan untuk mengetahui seberapa besar selisih pembacaan sensor ICM-20948 terhadap sensor referensi.

Hasil pengujian sensor gyroscope pada masing-masing sumbu kemudian disajikan pada tabel 4.5, 4.6, dan 4.7 di bawah. Data yang diperoleh digunakan untuk mengevaluasi tingkat akurasi sensor ICM-20948 dalam mengukur percepatan pada ketiga sumbu pengukuran. Semakin kecil nilai error yang diperoleh, maka semakin baik tingkat kesesuaian hasil pembacaan sensor terhadap sensor referensi.

Tabel 4.5 Hasil Uji Sensor Gyroscope pada Sumbu X

NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0284	0,0484	0,41%
2	0,0241	0,0422	0,42%
3	0,0025	0,0016	0,56%
4	0,0251	0,0595	0,57%
5	0,0337	0,0618	0,45%
6	0,0971	0,0852	0,13%
7	0,0894	0,0682	0,31%
8	0,0539	0,0778	0,30%
9	0,1051	0,1171	0,10%
10	0,1088	0,1307	0,16%
Rata-rata Error			0,25%

(Sumber : Dokumentasi Pribadi Penulis,2026).

Tabel 4.6 Hasil Uji Sensor Gyroscope pada Sumbu Y

NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0042	0,0052	0,19%
2	0,0034	0,0020	0,7%
3	0,0066	0,0046	0,43%
4	0,0149	0,0142	0,049%
5	0,0242	0,0229	0,056%
6	0,0018	0,0027	0,33%
7	0,0049	0,0032	0,53%
8	0,0063	0,0044	0,43%
9	0,0011	0,0016	0,31%
10	0,0019	0,0021	0,095%
Rata-rata Error			0,31%

(Sumber : Dokumentasi Pribadi Penulis,2026).

Tabel 4.7 Hasil Uji Sensor Gyroscope pada Sumbu Z


NO	Data Sensor IMU ICM-20948 (m/s ²)	Data Sensor iPhone 13 Mini (m/s ²)	Error
1	0,0019	0,0011	0,72%
2	0,0012	0,0016	0,25%
3	0,0021	0,0019	0,10%
4	0,0027	0,0024	0,12%
5	0,0032	0,0026	0,23%
6	0,0037	0,0035	0,057%
7	0,0038	0,0039	0,025%
8	0,0029	0,0022	0,31%
9	0,0024	0,0019	0,26%
10	0,0017	0,0012	0,41%
Rata-rata Error			0,24%

(Sumber : Dokumentasi Pribadi Penulis,2026)

4.3.3 Hasil Pengujian Parsial Sensor Magnetometer

Pengujian parsial sensor magnetometer seperti pada gambar 4.10 di bawah dilakukan untuk mengetahui kemampuan sensor magnetometer pada modul IMU ICM-20948 dalam mendeteksi medan magnet pada masing-masing sumbu pengukuran, yaitu sumbu X, Y, dan Z. Pengujian ini bertujuan untuk mengevaluasi tingkat akurasi sensor sebelum digunakan pada tahap pengolahan data dan pengujian sistem secara keseluruhan.

Pada penelitian ini, hasil pembacaan sensor magnetometer ICM-20948 dibandingkan dengan hasil pembacaan sensor magnetometer yang terdapat pada iPhone 13 Mini sebagai data acuan. Pengujian dilakukan dengan menempatkan kedua perangkat pada orientasi yang sama sehingga medan magnet yang diterima oleh kedua sensor berada pada kondisi yang serupa. Data yang diamati berupa nilai medan magnet pada sumbu X, Y, dan Z yang dihasilkan oleh kedua perangkat. Perbandingan antara data sensor ICM-20948 dan sensor referensi dilakukan untuk mengetahui tingkat kesesuaian hasil pengukuran. Selanjutnya, nilai persentase error dihitung menggunakan persamaan rumus (4.1) untuk mengetahui besarnya perbedaan pembacaan antara kedua sensor.



Gambar 4.10 Pengujian Parsial Sensor Magnetometer
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Hasil pengujian sensor magnetometer pada masing-masing sumbu pengukuran kemudian disajikan dalam bentuk tabel 4.8, 4.9, dan 4.10 di bawah. Data yang diperoleh digunakan untuk mengevaluasi kemampuan sensor ICM-20948 dalam mengukur medan magnet pada sumbu X, Y, dan Z. Semakin kecil nilai error yang dihasilkan, maka semakin tinggi tingkat kesesuaian hasil pembacaan

sensor terhadap sensor referensi. Hasil pengujian ini menjadi salah satu indikator bahwa sensor magnetometer pada modul ICM-20948 mampu memberikan data yang cukup akurat untuk digunakan pada penelitian ini.

Tabel 4.8 Hasil Uji Sensor Magnetometer pada Sumbu X

NO	Data Sensor IMU ICM-20948 (μ T)	Data Sensor iPhone 13 Mini (μ T)	Error
1	19,35	21,27	0,090%
2	19,65	21,51	0,086%
3	19,05	21,51	0,11%
4	19,80	21,44	0,076%
5	19,95	21,51	0,072%
6	18,90	21,50	0,12%
7	18,75	21,49	0,12%
8	19,05	21,42	0,11%
9	18,75	21,47	0,12%
10	18,60	21,56	0,13%
Rata-rata Error			0,10%

(Sumber : Dokumentasi Pribadi Penulis,2026).

Tabel 4.9 Hasil Uji Sensor Magnetometer pada Sumbu Y

NO	Data Sensor IMU ICM-20948 (μ T)	Data Sensor iPhone 13 Mini (μ T)	Error
1	59,85	31,52	0,89%
2	59,52	31,29	0,90%
3	58,05	31,12	0,86%
4	58,20	31,19	0,86%
5	58,25	31,04	0,87%
6	58,50	31,13	0,87%
7	57,90	31,02	0,86%
8	57,75	31,15	0,85%
9	57,30	31,05	0,84%

NO	Data Sensor IMU ICM-20948 (μT)	Data Sensor iPhone 13 Mini (μT)	Error
10	56,95	30,99	0,83%
Rata-rata Error			0,86%

(Sumber : Dokumentasi Pribadi Penulis,2026).

Tabel 4.10 Hasil Uji Sensor Magnetometer pada Sumbu Z

NO	Data Sensor IMU ICM-20948 (μT)	Data Sensor iPhone 13 Mini (μT)	Error
1	26,10	30,62	0,14%
2	25,35	30,54	0,16%
3	26,85	30,47	0,11%
4	26,25	30,35	0,13%
5	26,40	30,44	0,13%
6	25,65	30,56	0,16%
7	25,80	30,30	0,14%
8	27,15	30,24	0,10%
9	27,30	30,65	0,10%
10	26,70	30,29	0,11%
Rata-rata Error			0,11%

(Sumber : Dokumentasi Pribadi Penulis,2026).

4.4 Tahap Pre-Processing Data

Tahapan pre-processing data dilakukan untuk mempersiapkan data hasil pembacaan sensor agar dapat digunakan secara optimal pada proses pelatihan model. Data yang diperoleh dari sensor IMU masih berupa data mentah yang mengandung noise dan belum terstruktur, sehingga diperlukan beberapa tahapan pengolahan sebelum digunakan sebagai input pada model pembelajaran mesin. Adapun tahapan pre-processing yang dilakukan meliputi pengumpulan data, filtering, windowing, serta pembagian data menjadi data latih dan data uji.

4.4.1 Pengumpulan Data

Pengumpulan data dilakukan menggunakan sensor Inertial Measurement Unit (IMU) yang terpasang pada perangkat sarung tangan pintar berbasis

mikrokontroler ESP32. Sensor ini digunakan untuk merekam data gerakan tangan yang meliputi nilai accelerometer, gyroscope, dan magnetometer pada sumbu X, Y, dan Z secara real-time selama aktivitas berlangsung. Proses pengambilan data dilakukan dengan melakukan berbagai variasi gerakan yang merepresentasikan aktivitas pengelasan, sehingga diperoleh pola gerakan yang beragam dan dapat digunakan sebagai dataset penelitian. Setiap gerakan dilakukan secara berulang untuk meningkatkan jumlah dan konsistensi data yang diperoleh. Data hasil pembacaan sensor kemudian disimpan dan diberi label sesuai dengan jenis gerakan yang dilakukan pada saat perekaman. Tahap pelabelan ini bertujuan untuk memudahkan proses identifikasi pola gerakan pada tahap pengolahan data dan pelatihan model kecerdasan buatan, sehingga sistem yang dikembangkan mampu mengenali dan mengklasifikasikan aktivitas pengelasan dengan tingkat akurasi yang lebih baik. Contoh hasil pengumpulan data yang diperoleh dari sensor IMU dapat dilihat pada Tabel 4.11 dibawah ini.

Tabel 4.11 Data yang Telah dilabeli

No	Time	Second Elapse	Accel X	Accel Y	Accel Z	Gyro X	Gyro Y	Gyro Z	Mag X	Mag Y	Mag Z	Label
1.	1,76E+18	0,0886	0,3483	-	-	-	-	0,0523	19,609	32,431	-	1G
				0,0603	0,0977	0,0484	0,0606				30,623	
2.	1,76E+18	0,1085	0,1413	-	-	-	-	0,0078	19,680	32,515	-	1G
				0,1885	0,0886	0,0422	0,0100				30,548	
3.	1,76E+18	0,1284	0,1903	-	-	-	-	0,0249	19,583	32,366	-	1G
				0,0954	0,1751	0,0595	0,0002				30,471	
4.	1,76E+18	0,1483	-	0,0009	-	-	0,0446	0,0016	19,766	32,436	-	1G
			0,1535		0,2463	0,0618					30,357	
5.	1,76E+18	0,1681	-	-	-	-	-	0,0063	19,823	32,510	-	1G
			0,0519	0,1714	0,0358	0,0682	0,0305				30,448	
6.	1,76E+18	0,1880	0,0325	-	0,1285	-	-	0,0001	19,764	32,540	-	1G
				0,0786		0,0890	0,0594				30,563	
7.	1,76E+18	0,2079	-	-	0,0795	-	-	-	19,815	32,533	-	1G
			0,0687	0,1844		0,0852	0,0562	0,0181			30,096	
8.	1,76E+18	0,2278	0,0266	0,0777	0,1319	-	-	-	19,757	32,604	-	1G
						0,0778	0,0427	0,0077			30,065	
9.	1,76E+18	0,2477	-	-	0,1024	-	0,0113	0,0167	19,711	32,809	-	1G
			0,3283	0,1168		0,0882					30,300	
10.	1,76E+18	0,2676	-	-	0,1407	-	-	0,0621	19,849	32,936	-	1G
			0,3128	0,2122		0,0854	0,0041				30,243	

(Sumber : Dokumentasi Pribadi Penulis,2026).

Persebaran jumlah dataset yang digunakan pada penelitian ini dapat dilihat pada Tabel 4.12 di bawah. Dataset terdiri atas empat kelas posisi pengelasan, yaitu Flat, Horizontal, Vertical, dan Overhead. Masing-masing kelas memiliki jumlah data yang sama, yaitu sebanyak 42.185 sampel. Dengan demikian, total dataset yang digunakan dalam penelitian ini berjumlah 168.740 sampel. Distribusi dataset yang seimbang pada setiap kelas bertujuan untuk menghindari terjadinya *class imbalance*, sehingga model LSTM dapat mempelajari karakteristik setiap kelas secara proporsional tanpa adanya dominasi dari salah satu kelas. Keseimbangan

jumlah data antar kelas juga diharapkan dapat meningkatkan kemampuan generalisasi model dalam proses klasifikasi.


Tabel 4.12 Jumlah dataset yang digunakan

Kelas	Durasi	File	Jumlah Dataset
1G	12 Menit	CSV	42.185
2G	12 Menit	CSV	42.185
3G	12 Menit	CSV	42.185
4G	12 menit	CSV	42.185
Jumlah Dataset			168.740


(Sumber : Dokumentasi Pribadi Penulis,2026).

4.4.2 Filtering Data


Data hasil pembacaan sensor IMU cenderung mengandung *noise* yang disebabkan oleh gangguan lingkungan maupun karakteristik sensor itu sendiri. Oleh karena itu, dilakukan proses *filtering* untuk mengurangi *noise* sehingga menghasilkan data yang lebih halus, stabil, dan lebih merepresentasikan pola pergerakan yang sebenarnya. Proses ini juga bertujuan untuk meningkatkan kualitas data sebelum digunakan pada tahapan pengolahan selanjutnya. Hasil perbandingan data sebelum dan sesudah proses *filtering* dapat dilihat pada grafik Gambar 4.11, Gambar 4.12, dan Gambar 4.13. di bawah.



Gambar 4.11 Grafik *Filtering* Accelerometer
(Sumber: Dokumentasi Pribadi Penulis, 2026)



Gambar 4.12 Grafik *Filtering* Gyroscope
(Sumber: Dokumentasi Pribadi Penulis, 2026)



Gambar 4.13 Grafik *Filtering* Magnetometer
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Metode filtering yang digunakan dalam penelitian ini adalah low-pass filter Butterworth. Filter ini dipilih karena memiliki respon frekuensi yang halus tanpa distorsi yang signifikan pada sinyal utama, sehingga mampu mempertahankan karakteristik sinyal dengan baik. Secara umum, filter low-pass bekerja dengan

melewatkan komponen sinyal berfrekuensi rendah dan meredam komponen berfrekuensi tinggi yang umumnya merupakan noise.

Secara matematis, karakteristik filter Butterworth dapat dinyatakan sebagai berikut:

$$|H(j\omega)| = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}}} \quad (4.2)$$

Di mana:

$|H(j\omega)|$: respon amplitudo filter terhadap frekuensi

ω : frekuensi sinyal masukan

ω_c : frekuensi cutoff (batas antara sinyal yang dilewatkan dan diredam)

n : orde filter yang menentukan tingkat ketajaman penyaringan

$\left(\frac{\omega}{\omega_c}\right)^{2n}$: faktor yang mempengaruhi tingkat pelemahan sinyal pada frekuensi tertentu.

4.3.3 Windowing Data

Hasil proses *windowing* pada setiap kelas dapat dilihat pada Tabel 4.13. Sebelum dilakukan proses *windowing*, masing-masing kelas memiliki jumlah data mentah (*raw data*) sebanyak 42.185 sampel yang diperoleh dari hasil akuisisi data sensor IMU. Data mentah tersebut masih berupa sinyal kontinu sehingga belum dapat langsung digunakan sebagai masukan pada model LSTM. Oleh karena itu, dilakukan proses *windowing* menggunakan teknik *sliding window* untuk membagi data menjadi beberapa segmen dengan ukuran jendela (*window size*) yang telah ditentukan. Setiap segmen yang dihasilkan merepresentasikan satu urutan data (*sequence*) yang akan digunakan sebagai satu sampel masukan pada proses pelatihan model LSTM. tahap pelatihan dan pengujian model LSTM dengan jumlah data yang seragam untuk setiap kelas.

Tabel 4.13 Hasil *Windowing*

Kelas	Jumlah Data <i>Raw</i>	Jumlah <i>Window</i>
1G	42.185	842
2G	42.185	842

Kelas	Jumlah Data <i>Raw</i>	Jumlah <i>Window</i>
3G	42.185	842
4G	42.185	842

(Sumber : Dokumentasi Pribadi Penulis,2026).

Secara matematis, jika data hasil preprocessing dinyatakan sebagai:

$$X = \{x_1, x_2, x_3, \dots, x_N\} \quad (4.3)$$

dan ukuran window dinyatakan sebagai w , maka sequence ke- i dibentuk sebagai:

$$X_i = \{x_i, x_{i+1}, \dots, x_{i+w-1}\} \quad (4.4)$$

dengan target label:

$$y_i = y_{i+w} \quad (4.5)$$

Berdasarkan proses tersebut, setiap kelas menghasilkan 842 window, sehingga jumlah *window* yang dihasilkan memiliki distribusi yang seimbang pada seluruh kelas. Proses *windowing* bertujuan untuk mengubah data sensor yang semula berupa rangkaian sinyal kontinu menjadi kumpulan data berurutan (*sequence*) dengan panjang yang tetap. Setiap *window* terdiri atas 100 time step dengan 9 fitur sensor, yang meliputi tiga sumbu akselerometer, tiga sumbu giroskop, dan tiga sumbu magnetometer. Hasil *windowing* inilah yang selanjutnya digunakan sebagai masukan (*input*) pada model Long Short-Term Memory (LSTM) untuk proses pelatihan dan pengujian.

4.4.4 Split Data Train dan Test

Setelah proses *windowing* selesai, tahap selanjutnya adalah melakukan pembagian dataset menjadi data latih (*training data*) dan data uji (*testing data*). Proses pembagian data ini bertujuan agar model dapat mempelajari pola dan karakteristik dari data latih selama proses pelatihan, kemudian mengevaluasi kemampuan model dalam melakukan klasifikasi menggunakan data uji yang belum pernah digunakan sebelumnya. Dengan demikian, hasil pengujian dapat memberikan gambaran mengenai kemampuan generalisasi model terhadap data baru. Pembagian dataset dilakukan sesuai dengan rasio yang telah ditentukan pada tahap perancangan penelitian. Hasil pembagian data latih dan data uji pada setiap kelas dapat dilihat pada Tabel 4.14 di bawah.

Tabel 4.14 Hasil *Split Data*

Kelas	Data Train	Data Test
1G	673	169
2G	674	168
3G	673	169
4G	674	168

(Sumber : Dokumentasi Pribadi Penulis,2026).

Pada penelitian ini, data dibagi dengan perbandingan 80% untuk data training dan 20% untuk data testing. secara matematis, jika jumlah total data sequence dinyatakan sebagai N , maka jumlah data training dan data testing dapat dihitung menggunakan persamaan berikut:

$$N_{train} = 0.8 \times N \quad (4.6)$$

$$N_{test} = 0.2 \times N \quad (4.7)$$

Berdasarkan hasil pembagian dataset, diperoleh 2.694 data latih (*training data*) dan 674 data uji (*testing data*) yang berasal dari empat kelas posisi pengelasan. Data latih memiliki bentuk (2694, 100, 9), yang menunjukkan bahwa terdapat 2.694 sampel data latih, di mana setiap sampel terdiri atas 100 *time step* dengan 9 fitur sensor yang meliputi tiga sumbu akselerometer, tiga sumbu giroskop, dan tiga sumbu magnetometer. Sementara itu, data uji memiliki bentuk (674, 100, 9) dengan struktur yang sama. Pembagian dataset ini memungkinkan model LSTM untuk mempelajari karakteristik data selama proses pelatihan menggunakan data latih, kemudian mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dipelajari sebelumnya menggunakan data uji.

4.5 Tahap Training Metode *Long Short-Term Memory* (LSTM)

Tahapan training model dilakukan untuk membangun sistem klasifikasi berdasarkan data hasil pre-processing yang telah diperoleh dari sensor IMU. Pada tahap ini, data yang telah melalui proses pengolahan seperti filtering, windowing, dan pembagian data digunakan sebagai input untuk melatih model pembelajaran mesin agar mampu mengenali pola pergerakan secara optimal. Proses training bertujuan untuk menghasilkan model yang dapat mempelajari hubungan antar data dalam suatu urutan waktu, sehingga mampu melakukan klasifikasi terhadap jenis

gerakan yang dihasilkan. Selain itu, pada tahap ini juga dilakukan evaluasi performa model untuk mengetahui tingkat akurasi dan kemampuan model dalam melakukan prediksi terhadap data baru.

4.5.1 Training Model dengan Metode LSTM

Proses training model dilakukan menggunakan metode Long Short-Term Memory (LSTM). Metode LSTM dipilih karena mampu mempelajari pola data sekuensial atau time series dengan baik, sehingga cocok digunakan untuk mengolah data sensor IMU yang berupa data berurutan terhadap waktu. Data yang digunakan pada proses training berasal dari sensor accelerometer, gyroscope, dan magnetometer yang telah melalui tahap preprocessing dan pelabelan data. Proses training dilakukan menggunakan bahasa pemrograman Python dengan bantuan library TensorFlow dan Keras. Pada tahap ini, dataset dibagi menjadi data training dan data testing untuk mengevaluasi performa model. Model dilatih selama 40 epoch agar sistem dapat mempelajari pola gerakan pada masing-masing kelas secara optimal. Adapun kelas yang digunakan pada penelitian ini terdiri dari empat kelas gerakan, yaitu 1G, 2G, 3G, dan 4G.

Layer (type)	Output Shape	Param #
lstm_10 (LSTM)	(None, 20, 128)	70,656
batch_normalization_10 (BatchNormalization)	(None, 20, 128)	512
dropout_15 (Dropout)	(None, 20, 128)	0
lstm_11 (LSTM)	(None, 64)	49,408
batch_normalization_11 (BatchNormalization)	(None, 64)	256
dropout_16 (Dropout)	(None, 64)	0
dense_10 (Dense)	(None, 64)	4,160
dropout_17 (Dropout)	(None, 64)	0
dense_11 (Dense)	(None, 4)	260

Gambar 4.14 Arsitektur Hasil *Training* dengan Metode LSTM
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.14 menunjukkan arsitektur model LSTM yang digunakan pada penelitian ini. Model terdiri dari dua layer LSTM, layer batch normalization, dropout, dan dense layer. Layer LSTM pertama menggunakan 128 unit dengan output sequence sebesar (None, 20, 128), sedangkan layer LSTM kedua

menggunakan 64 unit dengan output sebesar (None, 64). Penggunaan batch normalization bertujuan untuk menjaga kestabilan proses training, sementara dropout digunakan untuk mengurangi risiko overfitting pada model. Selanjutnya, hasil keluaran dari layer LSTM diproses menggunakan dense layer untuk melakukan proses klasifikasi. Layer output menggunakan empat neuron yang merepresentasikan empat kelas gerakan yang digunakan pada penelitian ini. Berdasarkan hasil training, model mampu mempelajari pola data sensor dengan baik dan menghasilkan performa klasifikasi yang cukup optimal.

Batch Normalization bekerja dengan melakukan normalisasi terhadap nilai aktivasi yang dihasilkan oleh layer sebelumnya. Proses ini diawali dengan menghitung nilai rata-rata (*mean*) dari setiap *mini-batch* menggunakan Persamaan (4.8).

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (4.8)$$

Keterangan:

- μ_B = rata-rata (*mean*) pada satu *mini-batch*.
- m = jumlah data dalam satu *mini-batch*.
- x_i = nilai aktivasi ke-i.

Selanjutnya dihitung nilai variansi untuk mengetahui tingkat penyebaran data terhadap nilai rata-ratanya menggunakan Persamaan (4.9).

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (4.9)$$

Keterangan:

- σ_B^2 = variansi *mini-batch*.
- x_i = nilai aktivasi ke-i.
- μ_B = rata-rata *mini-batch*.

Setelah nilai rata-rata dan variansi diperoleh, dilakukan proses normalisasi terhadap setiap nilai aktivasi menggunakan Persamaan (4.10).

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (4.10)$$

Keterangan:

- $\hat{x}_i$ = hasil normalisasi.
- x_i = nilai aktivasi ke-i.

- μ_B = rata-rata *mini-batch*.
- σ_B^2 = variansi *mini-batch*.
- ε = konstanta kecil untuk menghindari pembagian dengan n

Selanjutnya dilakukan proses transformasi menggunakan parameter skala (*scale*) dan parameter pergeseran (*shift*) yang dipelajari selama proses *training*. Transformasi tersebut dinyatakan pada Persamaan (4.11).

$$y_i = \gamma \hat{x}_i + \beta \quad (4.11)$$

Keterangan:

- y_i = keluaran (*output*) Batch Normalization.
- γ = parameter skala (*scale*).
- β = parameter pergeseran (*shift*).
- $\hat{x}_i$ = hasil normalisasi.

Untuk mengetahui pengaruh layer Batch Normalization terhadap keluaran layer LSTM, dilakukan analisis terhadap distribusi nilai aktivasi sebelum dan sesudah proses Batch Normalization. Analisis ini bertujuan untuk menunjukkan bahwa layer Batch Normalization melakukan normalisasi terhadap nilai aktivasi tanpa mengubah dimensi data yang dihasilkan oleh layer sebelumnya.

Tabel 4.15 Hasil Analisis *Batch Normalization*

Layer	Mean	Standard Deviation
LSTM 1	-0,0037	0,0607
<i>Batch Normalization 1</i>	0,0048	0,1700
LSTM 2	-0,0138	0,2720
<i>Batch Normalization 2</i>	-0,0032	0,7031

(Sumber : Dokumentasi Pribadi Penulis, 2026).

Berdasarkan Tabel 4.15, dilakukan analisis terhadap output yang dihasilkan sebelum dan sesudah proses Batch Normalization pada kedua layer LSTM. Analisis dilakukan menggunakan dua parameter statistik, yaitu mean dan standar deviasi, untuk mengetahui perubahan distribusi nilai aktivasi setelah melewati layer Batch Normalization. Pada layer LSTM pertama, nilai rata-rata (*mean*) output sebesar -0,0037, kemudian berubah menjadi 0,0048 setelah melewati Batch Normalization 1. Nilai tersebut menunjukkan bahwa distribusi data tetap berada di sekitar nilai nol. Sementara itu, nilai standar deviasi berubah dari 0,0607 menjadi 0,1700, yang menunjukkan adanya penyesuaian terhadap penyebaran nilai aktivasi. Meskipun penyebaran nilai mengalami perubahan, Batch Normalization tetap


mempertahankan distribusi data agar lebih stabil sebelum diteruskan ke layer berikutnya.

Selanjutnya, pada layer LSTM kedua, nilai rata-rata (*mean*) output berubah dari -0,0138 menjadi -0,0032 setelah melewati Batch Normalization 2. Nilai tersebut menunjukkan bahwa rata-rata aktivasi kembali dipusatkan mendekati nol. Di sisi lain, nilai standar deviasi meningkat dari 0,2720 menjadi 0,7031. Perubahan ini terjadi karena pada proses pelatihan, Batch Normalization tidak hanya melakukan normalisasi, tetapi juga melakukan penyesuaian skala (*scaling*) dan pergeseran (*shifting*) melalui parameter yang dipelajari selama training, sehingga distribusi aktivasi menjadi lebih sesuai dengan kebutuhan model.

Secara keseluruhan, hasil pada Tabel 4.15 menunjukkan bahwa penerapan Batch Normalization berhasil menjaga nilai aktivasi tetap berada di sekitar nilai nol tanpa mengubah dimensi data yang dihasilkan oleh layer LSTM. Kondisi ini membantu mengurangi perubahan distribusi data antar layer (*internal covariate shift*), sehingga proses pembelajaran menjadi lebih stabil, mempercepat konvergensi model, serta mendukung peningkatan performa klasifikasi pada proses training.

4.5.2 Grafik *Accuracy* dan *Loss*


Setelah proses training model menggunakan metode *Long Short-Term Memory* (LSTM) selesai dilakukan, tahap selanjutnya adalah evaluasi performa model menggunakan grafik *accuracy* dan *loss*. Evaluasi ini bertujuan untuk mengetahui kemampuan model dalam mengklasifikasikan data gerakan berdasarkan data sensor IMU yang telah dikumpulkan. Grafik *accuracy* digunakan untuk menunjukkan tingkat ketepatan klasifikasi model, sedangkan grafik *loss* digunakan untuk melihat besarnya kesalahan prediksi selama proses pelatihan. Selain itu, perbandingan antara nilai *accuracy* dan *loss* pada data training dan validasi juga digunakan untuk mengamati proses pembelajaran model serta mendeteksi kemungkinan terjadinya *overfitting* atau *underfitting*. Hasil evaluasi tersebut digunakan untuk menilai kualitas model yang dikembangkan dalam mengenali pola gerakan pengelasan dan menentukan tingkat keandalan model dalam melakukan klasifikasi gerakan.



Gambar 4.15 Grafik *Accuracy*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.15 di atas menunjukkan grafik *accuracy* selama proses training model. Berdasarkan grafik tersebut, nilai training *accuracy* dan validation *accuracy* mengalami peningkatan secara bertahap seiring bertambahnya epoch. Pada awal proses training, nilai *accuracy* masih berada pada rentang rendah, kemudian meningkat hingga mencapai kondisi yang stabil pada akhir epoch. Selain itu, selisih antara training *accuracy* dan validation *accuracy* relatif kecil sehingga menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan. Hasil tersebut menunjukkan bahwa model mampu mempelajari pola data sensor dengan baik dan memiliki kemampuan generalisasi yang cukup baik terhadap data validasi.

Sedangkan Gambar 4.16 di bawah menunjukkan grafik *loss* selama proses training model Long Short-Term Memory (LSTM). Terlihat bahwa nilai *loss* pada data training dan validation mengalami penurunan secara bertahap seiring bertambahnya jumlah epoch. Hal ini menunjukkan bahwa model semakin mampu meminimalkan kesalahan prediksi dan mempelajari pola data dengan baik. Pada akhir proses training, kurva *training loss* dan *validation loss* berada pada nilai yang relatif rendah dan stabil, serta tidak menunjukkan perbedaan yang signifikan. Kondisi ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting*.



Gambar 4.16 Grafik *Loss*
(Sumber: Dokumentasi Pribadi Penulis, 2026)


4.5.3 Confusion Matrix dan *Accuracy Table*

Confusion matrix hasil pengujian model LSTM dalam mengklasifikasikan kualitas jaringan ke dalam empat kelas, yaitu kelas 0 (1G), kelas 1 (2G), kelas 2 (3G), dan kelas 3 (4G). *Confusion matrix* merupakan matriks berukuran $K \times K$, dengan K menyatakan jumlah kelas yang digunakan. Setiap elemen matriks menyatakan jumlah data dari kelas aktual i yang diprediksi sebagai kelas j , yang secara matematis dapat dinyatakan sebagai:

$$CM_{ij} = \sum_{n=1}^N I(y_n = i \wedge \hat{y}_n = j) \quad (4.12)$$

dengan y_n sebagai label aktual, $\hat{y}_n$ sebagai label prediksi, dan N sebagai jumlah total data uji. Nilai pada diagonal utama menunjukkan jumlah data yang berhasil diprediksi dengan benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Berdasarkan gambar tersebut, terlihat bahwa sebagian besar data berada pada diagonal utama, yang menandakan bahwa model mampu melakukan klasifikasi dengan baik pada setiap kelas. kelas 1G berhasil diprediksi dengan benar sebanyak 163 data dari total 169 data uji, sedangkan 6 data lainnya mengalami kesalahan klasifikasi ke kelas lain. Kelas 2G berhasil diprediksi dengan benar sebanyak 154 data dari total 168 data uji, dengan 14 data mengalami kesalahan

prediksi. Selanjutnya, kelas 3G berhasil diprediksi dengan benar sebanyak 159 data dari total 169 data uji, sedangkan 10 data lainnya salah diklasifikasikan. Adapun kelas 4G berhasil diprediksi dengan benar sebanyak 158 data dari total 168 data uji, dengan 10 data mengalami kesalahan klasifikasi, seperti yang dapat dilihat pada Gambar 4.17 di bawah



Gambar 4.17 Confusion Matrix
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Hasil tersebut diperkuat oleh Tabel 4.16 yang ada di bawah, yang menampilkan nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas. Nilai *precision* dihitung menggunakan persamaan:

$$=Precision = \frac{TP}{TP+FP} \quad (4.13)$$

nilai *recall* dihitung dengan:

$$Recall = \frac{TP}{TP+FN} \quad (4.14)$$

sedangkan *F1-Score* diperoleh melalui:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4.15)$$

Tabel 4.16 *Classification Report*

Classification Report			
Class	Precision	Recall	F1-Score
0/1G	98%	96%	97%
1/2G	97%	92%	94%
2/3G	97%	94%	95%
3/4G	100%	98%	98%
Rata-rata	98%	95%	96%


(Sumber : Dokumentasi Pribadi Penulis,2026).

Berdasarkan hasil *classification report*, model LSTM menunjukkan performa yang sangat baik dalam mengklasifikasikan keempat posisi pengelasan. Pada kelas 1G diperoleh nilai precision sebesar 98%, recall sebesar 96%, dan F1-score sebesar 97%. Kelas 2G memiliki nilai precision sebesar 97%, recall sebesar 92%, dan F1-score sebesar 94%. Selanjutnya, pada kelas 3G, model memperoleh precision sebesar 97%, recall sebesar 94%, dan F1-score sebesar 95%. Sementara itu, kelas 4G menunjukkan performa terbaik dengan nilai precision sebesar 100%, recall sebesar 98%, dan F1-score sebesar 98%, yang menunjukkan bahwa hampir seluruh data pada kelas tersebut berhasil diklasifikasikan dengan benar, yang dihitung berdasarkan perbandingan jumlah prediksi benar terhadap seluruh data uji dengan persamaan:

$$Accuracy = \frac{\sum_{i=1}^K CM_{ii}}{N} \quad (4.16)$$


Secara keseluruhan, model menghasilkan nilai accuracy yang dihitung berdasarkan perbandingan antara jumlah prediksi yang benar terhadap keseluruhan data uji menggunakan Persamaan (4.16). Selain itu, model juga memperoleh nilai macro average precision sebesar 98%, macro average recall sebesar 95%, dan macro average F1-score sebesar 96%. Hasil tersebut menunjukkan bahwa model Long Short-Term Memory (LSTM) memiliki kemampuan yang tinggi dalam mengenali pola data *time-series* dari sensor IMU sehingga mampu mengklasifikasikan posisi pengelasan 1G, 2G, 3G, dan 4G dengan tingkat ketepatan yang sangat baik.

4.6 Hasil Perancangan *Dashboard*




Gambar 4.18 Halaman *Login* dan *Register*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Pada tampilan awal dashboard seperti yang terlihat pada Gambar 4.18 di atas, ditampilkan halaman *login* aplikasi *Welding Monitoring System*, yaitu sistem yang digunakan untuk memantau dan mengklasifikasikan aktivitas pengelasan secara *real-time* berbasis sensor IMU. Antarmuka dirancang sederhana dan profesional dengan form input email dan *password* serta tombol akses ke dashboard, sehingga pengguna dapat melakukan proses autentikasi sebelum mengakses fitur utama sistem. Selain itu, tersedia opsi registrasi bagi pengguna baru yang belum memiliki akun untuk dapat membuat akun dan memperoleh akses sesuai dengan hak yang diberikan. Halaman *login* juga dilengkapi dengan indikator keamanan berupa enkripsi *password* untuk menjaga kerahasiaan informasi pengguna yang tersimpan dalam basis data. Dengan adanya proses autentikasi tersebut, sistem dapat membatasi akses hanya kepada pengguna yang telah terdaftar, sehingga keamanan data dan pengelolaan akses pada aplikasi dapat lebih terjaga. Proses ini juga menjadi tahap awal sebelum pengguna dapat mengakses informasi monitoring dan hasil klasifikasi aktivitas pengelasan yang tersedia pada dashboard.




Gambar 4.19 Halaman Utama *Dashboard*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.19 di atas menunjukkan tampilan dashboard monitoring yang digunakan oleh administrator untuk memantau aktivitas pekerja secara *real-time*. Dashboard menyajikan informasi mengenai jumlah pengguna, jumlah pekerja aktif, serta hasil klasifikasi aktivitas menggunakan algoritma *Long Short-Term Memory* (LSTM) yang meliputi aktivitas yang diizinkan, tidak diizinkan, dan peringatan yang terdeteksi. Selain itu, fitur *Live Worker Monitoring* menampilkan identitas pekerja, status koneksi perangkat ESP32, waktu pembaruan data, serta hasil klasifikasi aktivitas yang diperbarui secara otomatis berdasarkan data yang diterima dari sensor IMU. Informasi tersebut memungkinkan administrator untuk mengetahui kondisi perangkat dan aktivitas pekerja tanpa perlu melakukan pemeriksaan secara langsung pada perangkat *wearable*. Dashboard juga memberikan gambaran kondisi aktivitas pekerja secara terpusat sehingga perubahan status atau hasil klasifikasi dapat diketahui dengan lebih cepat. Dengan tampilan informasi yang tersusun secara terpusat dan diperbarui secara *real-time*, dashboard ini memudahkan administrator dalam melakukan pemantauan, pengawasan, dan pengambilan keputusan secara lebih cepat dan efisien terhadap aktivitas pekerja selama proses pengelasan berlangsung.




Gambar 4.20 Tampilan *Add User*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.20 di atas menunjukkan tampilan halaman Add User yang digunakan oleh administrator untuk menambahkan akun pengguna baru ke dalam sistem. Halaman ini berfungsi sebagai sarana pengelolaan akun pengguna sehingga hanya pengguna yang telah terdaftar dan memiliki hak akses yang sesuai yang dapat menggunakan sistem monitoring. Pada halaman ini, administrator mengisi beberapa informasi penting, seperti nama lengkap, alamat email, kata sandi, dan peran (*role*) pengguna sebelum data disimpan ke dalam basis data. Seluruh informasi yang dimasukkan akan divalidasi oleh sistem untuk memastikan bahwa data telah sesuai dengan format yang ditentukan serta menghindari terjadinya kesalahan pengisian maupun duplikasi data. Setelah proses validasi dan penyimpanan berhasil dilakukan, akun pengguna baru akan terdaftar dan dapat digunakan untuk melakukan proses *login* sesuai dengan hak akses yang diberikan. Selain mempermudah proses penambahan pengguna baru, halaman ini juga mendukung pengelolaan hak akses secara lebih terstruktur sehingga keamanan sistem tetap terjaga. Dengan adanya fitur Add User, administrator dapat mengelola akun pengguna secara lebih mudah, efisien, dan terorganisir, sehingga mendukung operasional sistem monitoring secara keseluruhan.




Gambar 4.21 Tampilan *Add Worker*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.21 di atas menunjukkan tampilan halaman *Add Worker* yang digunakan oleh administrator untuk menambahkan data pekerja baru ke dalam sistem *Welding Monitor*. Pada halaman ini, administrator mengisi informasi yang meliputi kode pekerja, nama lengkap, alamat email, *Device ID*, *API Key*, akun pengguna yang akan dikaitkan dengan pekerja, serta menentukan posisi kerja (*Allowed Positions*) yang diizinkan sesuai dengan kebutuhan operasional. Selain itu, sistem juga menyediakan fitur *Generate API Key* yang berfungsi untuk menghasilkan kunci autentikasi secara otomatis, sehingga setiap perangkat memiliki identitas yang unik dan aman saat mengirimkan data ke server. Setelah seluruh data diisi dengan benar dan proses validasi berhasil dilakukan, administrator dapat menekan tombol *Add Worker* untuk menyimpan data ke dalam basis data. Data pekerja yang telah tersimpan selanjutnya akan digunakan sebagai identitas pada proses monitoring dan klasifikasi aktivitas pengelasan secara *real-time*. Dengan adanya fitur ini, proses pengelolaan data pekerja menjadi lebih terstruktur, memudahkan pengaitan antara akun pengguna dengan perangkat ESP32 yang digunakan, serta memastikan bahwa setiap pekerja hanya dapat melakukan aktivitas sesuai dengan konfigurasi dan hak akses yang telah ditentukan dalam sistem.



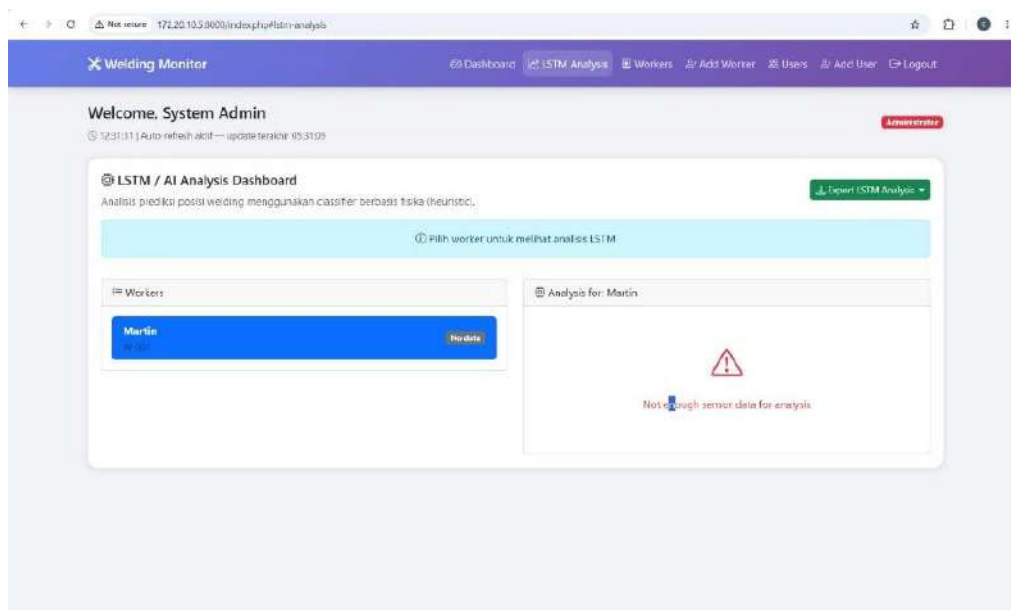
Gambar 4.22 Tampilan *Manage Users*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.22 diatas menunjukkan tampilan halaman *Manage Users* yang digunakan oleh *administrator* untuk mengelola seluruh akun pengguna yang telah terdaftar pada sistem *Welding Monitor*. Halaman ini menampilkan daftar pengguna dalam bentuk tabel yang berisi informasi berupa ID pengguna, nama lengkap, alamat email, peran (*role*), dan status akun sehingga administrator dapat memantau data pengguna dengan lebih mudah. Selain itu, tersedia fitur *Search Users* yang berfungsi untuk mempercepat proses pencarian pengguna berdasarkan nama atau email. Pada kolom *Actions*, administrator dapat melakukan berbagai pengelolaan akun, seperti mengubah informasi pengguna melalui fitur *Edit*, mengaktifkan atau menonaktifkan akun melalui fitur *Activate/Deactivate*, serta menghapus akun yang sudah tidak digunakan melalui fitur *Delete*. Sistem juga memberikan penanda *Current User* pada akun administrator yang sedang digunakan untuk masuk ke sistem sehingga akun tersebut tidak dapat dinonaktifkan maupun dihapus. Dengan adanya halaman ini, proses pengelolaan data pengguna dan pengaturan hak akses dapat dilakukan secara lebih terstruktur, efektif, dan aman sehingga hanya pengguna yang memiliki akun aktif yang dapat mengakses sistem sesuai dengan peran yang telah ditetapkan.



Gambar 4.23 Tampilan *Manage Workers*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.23 di atas menunjukkan tampilan halaman *Manage Workers* yang digunakan oleh administrator untuk mengelola seluruh data pekerja yang telah terdaftar pada sistem *Welding Monitor*. Halaman ini menyajikan informasi pekerja dalam bentuk tabel yang memuat data seperti ID pekerja, kode pekerja, nama, *Device ID*, pengguna yang ditugaskan (*Assigned User*), *API Key*, posisi kerja yang diizinkan (*Allowed Positions*), posisi terakhir yang terdeteksi (*Last Position*), status prediksi LSTM, serta status aktif pekerja. Untuk mempermudah pengelolaan data, sistem menyediakan fitur penyaringan berdasarkan nama pekerja dan status, serta kolom pencarian (*Search Workers*) yang memungkinkan administrator menemukan data pekerja dengan lebih cepat. Selain itu, tersedia beberapa fitur ekspor data, yaitu *Export CSV*, *Export PDF*, *Sensor Data*, *LSTM Data*, dan *Full Report (PDF)* yang dapat digunakan untuk mendokumentasikan dan menganalisis data pekerja. Pada kolom *Actions*, administrator dapat melakukan perubahan data pekerja, menghubungkan perangkat dengan sistem, maupun menghapus data pekerja yang sudah tidak digunakan. Fitur tersebut membantu administrator dalam mengelola informasi pekerja sekaligus memantau keterhubungan perangkat dan status klasifikasi yang dihasilkan sistem. Dengan adanya halaman ini, proses pengelolaan data pekerja, perangkat, dan hasil pemantauan dapat dilakukan secara terpusat sehingga mendukung administrasi sistem yang lebih efektif, dan terstruktur.




Gambar 4.24 Tampilan *LSTM Analysis*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Gambar 4.24 di atas menunjukkan tampilan halaman *LSTM / AI Analysis Dashboard* yang digunakan untuk menampilkan hasil analisis dan prediksi posisi pengelasan berdasarkan data sensor yang diterima dari perangkat pekerja. Pada halaman ini, administrator dapat memilih pekerja yang akan dianalisis melalui daftar *Workers* yang tersedia di sisi kiri, kemudian sistem akan menampilkan hasil analisis pada panel sebelah kanan secara otomatis berdasarkan data yang telah diproses oleh model *Long Short-Term Memory* (LSTM). Informasi yang ditampilkan meliputi hasil prediksi posisi pengelasan, tingkat kepercayaan (*confidence score*), serta riwayat hasil analisis yang dapat digunakan untuk memantau performa aktivitas pengelasan setiap pekerja. Selain itu, tersedia tombol *Export LSTM Analysis* yang dapat digunakan untuk mengekspor hasil analisis sebagai dokumentasi atau laporan, sehingga memudahkan proses penyimpanan data dan evaluasi hasil *monitoring*. Informasi tersebut juga dapat digunakan sebagai bahan evaluasi terhadap hasil klasifikasi aktivitas pengelasan setiap pekerja. Dengan adanya halaman ini, administrator dapat melakukan pemantauan dan analisis terhadap aktivitas pengelasan secara lebih mudah, cepat, dan terpusat, sehingga mendukung proses pengawasan dan pengambilan keputusan berdasarkan hasil prediksi sistem.

4.7 Hasil Integrasi Alat dengan *Dashboard*

Gambar 4.25 di bawah menunjukkan proses integrasi antara perangkat keras berbasis ESP32 yang dilengkapi sensor ICM-20948 dengan sistem *Welding Monitor Dashboard*. Proses diawali ketika sensor ICM-20948 melakukan pembacaan data gerakan pekerja yang meliputi nilai accelerometer pada sumbu X, Y, dan Z, nilai gyroscope pada ketiga sumbu, serta nilai magnetometer sebagai informasi orientasi. Sebelum proses pengambilan data dilakukan, pengguna memilih posisi pengelasan yang akan direkam melalui halaman *Welding Position IMU Data Logger*, kemudian melakukan proses kalibrasi sensor untuk memastikan hasil pembacaan memiliki tingkat akurasi yang baik dan meminimalkan kesalahan pengukuran. Setelah proses kalibrasi selesai, ESP32 mulai membaca data sensor secara periodik sesuai interval *sampling* yang telah ditentukan, kemudian mengolah dan mengirimkan data tersebut ke server melalui jaringan WiFi menggunakan protokol HTTP. Data yang diterima selanjutnya disimpan ke dalam basis data dan diproses oleh model *Long Short-Term Memory* (LSTM) untuk menghasilkan prediksi posisi pengelasan. Hasil prediksi tersebut kemudian ditampilkan pada *Welding Monitor Dashboard* secara *real-time*, sehingga administrator dapat memantau aktivitas pengelasan serta kondisi pekerja secara langsung melalui antarmuka sistem yang telah disediakan.



Gambar 4.25 Hasil Integrasi Alat dengan *Dashboard*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Data hasil pembacaan sensor selanjutnya diproses oleh ESP32 dan dikirimkan ke server melalui jaringan Wi-Fi menggunakan protokol HTTP dengan memanfaatkan REST API yang telah dikembangkan pada sistem. Pada tahap ini, ESP32 melakukan autentikasi menggunakan API Key yang telah didaftarkan sebelumnya sehingga hanya perangkat yang terdaftar yang dapat mengirimkan data ke server. Setelah server menerima permintaan dari ESP32, sistem melakukan proses validasi terhadap identitas perangkat dan format data yang dikirim. Apabila proses validasi berhasil, data sensor akan disimpan ke dalam basis data sebagai data historis yang dapat digunakan untuk monitoring maupun analisis lebih lanjut.

Selanjutnya, *dashboard Welding Monitor* mengambil data terbaru dari basis data secara otomatis melalui mekanisme pembaruan (*auto-refresh*) sehingga informasi yang ditampilkan selalu mengikuti kondisi perangkat secara real-time. Dashboard menampilkan identitas pekerja, perangkat yang digunakan, status koneksi perangkat, nilai sensor akselerometer, giroskop, dan magnetometer, serta hasil klasifikasi posisi pengelasan yang diperoleh dari modul analisis. Selain itu, data yang telah tersimpan juga digunakan sebagai masukan bagi model Long Short-Term Memory (LSTM) untuk melakukan prediksi posisi pengelasan berdasarkan pola pergerakan yang terekam dari sensor. Hasil prediksi beserta nilai tingkat kepercayaan (*confidence*) kemudian dikirim kembali ke dashboard sehingga administrator dapat memantau kondisi pekerja dan hasil analisis secara langsung.

Berdasarkan tampilan pada gambar, proses integrasi berlangsung dengan baik, yang ditunjukkan oleh keberhasilan ESP32 mendeteksi sensor ICM-20948, terhubung ke jaringan Wi-Fi, mengirimkan data ke server melalui API, serta diterimanya data oleh server untuk kemudian ditampilkan pada dashboard. Dengan demikian, seluruh proses mulai dari akuisisi data sensor, transmisi data, penyimpanan ke basis data, hingga visualisasi hasil monitoring dan analisis dapat berjalan secara terintegrasi dalam satu sistem yang mendukung pemantauan posisi pengelasan secara *real-time*.


4.8 Pengujian Baterai

Pengujian baterai dilakukan untuk mengetahui kemampuan sistem dalam beroperasi menggunakan sumber daya baterai Li-ion berkapasitas 2500 mAh. Pengujian dilakukan melalui dua tahap, yaitu perhitungan teoritis berdasarkan

konsumsi daya setiap komponen serta pengujian secara langsung yang mengacu pada kondisi operasional seorang pekerja pengelasan.

4.8.1 Perhitungan Teoritis

Perhitungan teoritis dilakukan untuk memperkirakan lama waktu operasi sistem berdasarkan kapasitas baterai dan konsumsi arus dari setiap komponen utama yang digunakan. Sistem pada penelitian ini menggunakan baterai Li-ion berkapasitas 2500 mAh sebagai sumber daya utama. Nilai konsumsi arus sensor ICM-20948 diperoleh berdasarkan spesifikasi pada *datasheet*, sedangkan konsumsi arus ESP32 diperoleh melalui pengukuran langsung menggunakan *USB current meter* KAWESI pada kondisi sistem beroperasi dengan Wi-Fi aktif dan sensor ICM-20948 terhubung. Pengukuran dilakukan untuk mengetahui konsumsi arus total sistem dalam kondisi operasi sebenarnya, sehingga hasil pengukuran dapat digunakan sebagai dasar dalam menentukan konsumsi arus masing-masing komponen serta memperkirakan lama waktu operasi baterai. Pengukuran juga dilakukan pada kondisi sistem menjalankan proses komunikasi data secara normal, sehingga nilai yang diperoleh dapat merepresentasikan kebutuhan daya sistem selama digunakan. Pengukuran konsumsi arus total sistem ditunjukkan pada Gambar 4.26 di bawah.



Gambar 4.26 Hasil Pengukuran dengan *Current Checker*
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Berdasarkan Gambar 4.26 di atas, sistem yang terdiri atas ESP32 dan sensor ICM-20948 dioperasikan dengan koneksi Wi-Fi aktif selama pengujian. Hasil

pengukuran menunjukkan konsumsi sebesar 180 mAh selama kurang lebih satu jam. Karena durasi pengujian adalah satu jam, nilai tersebut digunakan sebagai acuan konsumsi arus rata-rata sistem sebesar 180 mA. Nilai konsumsi arus sensor ICM-20948 sebesar 3,11 mA kemudian digunakan berdasarkan spesifikasi *datasheet* untuk menentukan perkiraan konsumsi arus ESP32.

Rincian konsumsi arus masing-masing komponen yang digunakan dalam perhitungan teoritis ditunjukkan pada Tabel 4.17 di bawah.

Tabel 4.17 Komponen dan Konsumsi Arusnya

No.	Komponen	Konsumsi Arus
1	Esp 32 Custom	176,89 mA
2	ICM-20948	3,11 mA
Total		180 mA

(Sumber : Dokumentasi Pribadi Penulis,2026).

Berdasarkan Tabel 4.17, total konsumsi arus sistem diperoleh dari penjumlahan konsumsi arus setiap komponen utama yang digunakan, yaitu ESP32-WROOM dan sensor ICM-20948. Besarnya arus total sistem dapat dihitung menggunakan Persamaan (4.17).

$$I_{total} = I_{ESP32} + I_{ICM} \quad (4.17)$$

dengan:

- I_{total} = total konsumsi arus sistem (mA)
- I_{ESP32} = konsumsi arus ESP32 (mA)
- I_{ICM} = konsumsi arus sensor ICM-20948 (mA)

Substitusi nilai berdasarkan Tabel 4.15

$$I_{total} = 176,89 + 3.11$$

$$I_{total} = 180 \text{ mA}$$

Selanjutnya estimasi lama waktu operasi baterai dihitung menggunakan Persamaan (4.18).

$$t = \frac{C}{I_{total}} \quad (4.18)$$

dengan:

- t = waktu operasi baterai (jam)
- C = kapasitas baterai (mAh)

- I_{total} = konsumsi arus total sistem (mA)

Substitusi nilai dilakukan sebagai berikut.

$$t = \frac{2500}{180}$$


$$t = 13,8 \text{ Jam}$$


Berdasarkan hasil perhitungan teoritis, baterai Li-ion berkapasitas 2500 mAh diperkirakan mampu menyuplai daya sistem selama 13,8 jam pada kondisi seluruh komponen bekerja secara kontinu dengan konsumsi arus total sebesar 180 mA. Hasil tersebut merupakan estimasi teoritis sehingga waktu operasi aktual dapat dipengaruhi oleh karakteristik baterai, fluktuasi konsumsi arus ESP32 selama pemrosesan data dan komunikasi, serta kondisi lingkungan saat sistem dioperasikan.

4.8.2 Pengujian Langsung

Pengujian langsung dilakukan untuk mengetahui kemampuan baterai dalam menyuplai daya sistem pada kondisi operasional yang menyerupai aktivitas pekerja pengelasan. Pengujian dilakukan dengan mengikuti jam kerja normal, yaitu sistem dioperasikan mulai pukul 08.00 WIB hingga 12.30 WIB, kemudian baterai diisi ulang selama 45 menit pada waktu istirahat. Setelah proses pengisian selesai, sistem kembali dioperasikan mulai pukul 13.15 WIB hingga 16.00 WIB. Selama periode pengujian, sistem dioperasikan dalam kondisi penggunaan normal dengan ESP32, sensor IMU ICM-20948, serta koneksi Wi-Fi tetap aktif untuk merepresentasikan kondisi sistem ketika digunakan secara langsung oleh pekerja. Pengoperasian dilakukan secara berkelanjutan selama jam kerja untuk mengetahui kemampuan baterai dalam mempertahankan kinerja perangkat tanpa dilakukan penggantian baterai. Selain itu, waktu pengisian selama periode istirahat turut dicatat untuk mengetahui pola penggunaan dan pengisian daya baterai dalam satu hari kerja. Hasil pengujian tersebut kemudian digunakan untuk mengevaluasi kesesuaian kapasitas baterai terhadap kebutuhan operasional sistem serta mengetahui apakah sistem mampu mendukung aktivitas monitoring selama jam kerja. Rincian waktu pengoperasian dan pengisian baterai selama pengujian disajikan pada Tabel 4.18 di bawah.

Tabel 4.18 Pengujian Baterai

Waktu	Kegiatan	Pengujian
07.50	Cek baterai	
08.00-12.30	Sistem realtime mulai aktif dan mengirim data ke dashboard sampai istirahat	
12.30-13.15	Pengecekan baterai dan sistem non-aktif untuk pengisian ulang baterai	 

Waktu	Kegiatan	Pengujian
13.18	Pengecekan baterai setelah diisi ulang	
13.21-16.00	Sistem kembali aktif	
16.00	Sistem non-aktif	
16.04	Pengecekan baterai dan pengisian ulang	 

(Sumber : Dokumentasi Pribadi Penulis,2026).

4.9 Pengujian Sistem Secara *Real-time*

Pengujian sistem secara *real-time* dilakukan untuk memastikan bahwa sistem yang dikembangkan mampu melakukan proses akuisisi data sensor, pengiriman data, klasifikasi aktivitas menggunakan algoritma Long Short-Term Memory (LSTM), serta menampilkan hasil klasifikasi pada dashboard secara berkelanjutan tanpa jeda yang signifikan. Pengujian dilakukan menggunakan perangkat ESP32 Custom yang terhubung dengan sensor IMU ICM-20948 sebagai sumber data percepatan dan kecepatan sudut. Data yang diperoleh kemudian dikirim ke server menggunakan protokol HTTP untuk diproses oleh model LSTM yang berjalan pada backend Python. Hasil klasifikasi selanjutnya disimpan ke dalam database dan ditampilkan pada dashboard monitoring secara *real-time*.

4.9.1 Pengujian *Hardware* dengan *Software*

Skenario pengujian hardware dengan software disusun sebagai acuan untuk memastikan bahwa setiap komponen pada sistem monitoring aktivitas pekerja dapat berfungsi dengan baik serta mampu bekerja secara terintegrasi sesuai dengan rancangan yang telah dibuat. Pengujian dilakukan secara bertahap dengan menguji setiap proses mulai dari perangkat keras (*hardware*) hingga perangkat lunak (*software*), sehingga dapat diketahui apakah sistem mampu menjalankan fungsi monitoring secara *real-time*.

Tahapan pengujian diawali dengan memastikan perangkat ESP32 berhasil terhubung ke jaringan Wi-Fi sebagai media komunikasi dengan server. Selanjutnya dilakukan pengujian pembacaan data dari sensor IMU ICM-20948 untuk memastikan nilai accelerometer, gyroscope, dan magnetometer dapat diperoleh secara kontinu dan akurat. Data sensor yang telah diperoleh kemudian dikirimkan ke server menggunakan protokol HTTP untuk diproses oleh backend Python yang mengimplementasikan algoritma *Long Short-Term Memory* (LSTM) dalam melakukan klasifikasi aktivitas pekerja.

Hasil klasifikasi yang diperoleh selanjutnya disimpan ke dalam basis data dan ditampilkan pada dashboard monitoring sehingga administrator dapat memantau aktivitas pekerja secara *real-time*. Setiap tahapan pengujian dilengkapi dengan bukti hasil implementasi sebagai bentuk verifikasi bahwa komunikasi antarperangkat, proses pengolahan data, hingga penyajian informasi pada

dashboard telah berjalan sesuai dengan fungsi yang diharapkan. Adapun skenario pengujian hardware dengan software yang dilakukan pada penelitian ini disajikan pada Tabel 4.19 di bawah.

Tabel 4.19 Pengujian Hardware dengan Software

Skenario Pengujian	Pengujian	Hasil
Esp32 berhasil terhubung ke jaringan	<pre> 09:45:42.603 => ... OK 09:45:43.563 => [WiFi] IP: 172.20.10.3 09:45:43.693 => [IMU] OK 09:45:43.693 => [NVS] Device ID: ESP32-001 09:45:43.725 => [NVS] Kalibrasi dimulai: AG1, MAG1 09:45:43.725 => [DEVICE] ID: ESP32-001 09:45:43.725 => [SERVER] Ready: http://172.20.10.3 09:45:43.725 => [STREAM] Menunggu tombol START... 09:45:44.690 => [TEST] Mencoba koneksi ke: http://172.20.10.3:8000/api/esp32_data.php 09:45:45.152 => [TEST] ☒ Koneksi ke server BERHASIL! Response: 200 09:45:45.152 => [TEST] Response body: {"success":true,"message":"Data received successful"} 09:46:34.972 => [CALIB-AG] Mulai dalam 5 detik... (letakkan alat diam 4 detik) 09:46:40.349 => [NVS] Data kalibrasi disimpan! 09:46:44.370 => [CALIB-AG] Selesai! 09:47:21.670 => [CALIB-MAG] Putar figure-8 selama beberapa detik... </pre>	Berhasil
Pembacaan sensor	<pre> [Sun Jul 26 14:49:20 2026] [ESP32] Raw input: {"device_id":"ESP32-001","d "gyro_x":-0.000834,"gyro_y":-0.003379,"gyro_z":-0.001827,"mag_x":97.95,"m "accel_z":-0.051284,"gyro_x":-0.003765,"gyro_y":-0.006577,"gyro_z":0.000 0772,"accel_y":0.256113,"accel_z":-0.154234,"gyro_x":0.003163,"gyro_y":- </pre>	Berhasil
Pengiriman data sensor ke server	<pre> 127.0.0.1 - - [26/Jul/2026 14:54:40] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:40] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:40] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:42] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:44] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:45] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:47] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:54:48] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:00] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:02] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:03] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:05] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:07] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:08] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:10] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:11] "POST /predict HTTP/1.1" 200 - 127.0.0.1 - - [26/Jul/2026 14:55:13] "POST /predict HTTP/1.1" 200 - </pre>	Berhasil
Klasifikasi aktivitas dengan metode LSTM	<pre> [Sun Jul 26 15:59:59 2026] [LSTMClassifier] WARNING: window di-resample dari 50 ke 100 sample, h [Sun Jul 26 15:59:59 2026] [ESP32] Classification result: {"position": "16", "confidence": 0.401826 6": 0.191289208934671, "ag": 0.17167377471923828}, "method": "lstm_v1", "resampled": true} [Sun Jul 26 15:59:59 2026] [ESP32] Position from classification: 16 [Sun Jul 26 15:59:59 2026] [ESP32] Processing data for worker: W-001 [Sun Jul 26 15:59:59 2026] [ESP32] Position allowed: YES [Sun Jul 26 15:59:59 2026] [ESP32] Saved to realtime_data [Sun Jul 26 15:59:59 2026] [ESP32] saved to welding_activities, ID: 13954 [Sun Jul 26 15:59:59 2026] [ESP32] Saving 50 IMU samples [Sun Jul 26 15:59:59 2026] [ESP32] saved IMU data [Sun Jul 26 15:59:59 2026] [ESP32] Saved prediction: 16 </pre>	Berhasil
Monitoring dashboard		Berhasil

(Sumber : Dokumentasi Pribadi Penulis,2026)

Berdasarkan hasil pengujian yang ditunjukkan pada Tabel 4.19, seluruh skenario pengujian berhasil dilaksanakan sesuai dengan fungsinya. Perangkat


ESP32 mampu terhubung dengan jaringan Wi-Fi, membaca data dari sensor ICM-20948, serta mengirimkan data ke server menggunakan protokol HTTP secara *real-time*. Selanjutnya, backend Python berhasil memproses data menggunakan algoritma *Long Short-Term Memory* (LSTM) dan menghasilkan klasifikasi aktivitas yang kemudian ditampilkan pada dashboard monitoring. Hasil pengujian menunjukkan bahwa seluruh komponen sistem dapat bekerja secara terintegrasi sehingga proses pemantauan aktivitas pekerja secara *real-time* dapat berjalan dengan baik.

4.9.2 Pengujian Hasil Klasifikasi pada *Dashboard*

Pengujian hasil klasifikasi pada dashboard dilakukan untuk memastikan bahwa hasil prediksi posisi pengelasan yang dihasilkan oleh algoritma *Long Short-Term Memory* (LSTM) dapat ditampilkan secara *real-time* pada dashboard monitoring. Selain itu, pengujian ini bertujuan untuk memverifikasi bahwa proses komunikasi data antara perangkat *wearable*, ESP32, server, basis data, dan dashboard telah berjalan dengan baik sehingga hasil klasifikasi dapat diterima dan ditampilkan tanpa mengalami kendala. Pada pengujian ini, pekerja melakukan aktivitas pengelasan pada masing-masing posisi, yaitu 1G, 2G, 3G, dan 4G, sesuai dengan skenario pengujian yang telah ditentukan. Sensor IMU ICM-20948 yang terpasang pada perangkat *wearable* merekam data pergerakan tangan secara kontinu, kemudian data tersebut dikirimkan oleh ESP32 ke server menggunakan protokol HTTP. Selanjutnya, data diproses menggunakan model LSTM untuk menghasilkan prediksi posisi pengelasan beserta nilai *confidence* yang menunjukkan tingkat keyakinan model terhadap hasil klasifikasi yang diperoleh.

Hasil klasifikasi kemudian disimpan ke dalam basis data dan ditampilkan secara otomatis pada dashboard monitoring. Informasi yang ditampilkan meliputi posisi pengelasan hasil prediksi, nilai *confidence* hasil klasifikasi, data sensor IMU, serta informasi pemantauan pekerja secara *real-time*. Pengujian dilakukan sebanyak 10 kali pada masing-masing kelas, sehingga diperoleh total 40 kali pengujian. Nilai *confidence* yang diperoleh pada setiap pengujian digunakan untuk mengevaluasi tingkat keyakinan model LSTM dalam mengklasifikasikan posisi pengelasan secara *real-time*.

Pengujian pertama dilakukan pada posisi pengelasan 1G. Pada pengujian ini, pekerja melakukan aktivitas pengelasan pada posisi 1G, kemudian data yang diperoleh dari sensor IMU dikirimkan oleh ESP32 ke server untuk diproses menggunakan model LSTM. Hasil prediksi yang diperoleh selanjutnya ditampilkan secara real-time pada dashboard monitoring beserta nilai confidence yang menunjukkan tingkat keyakinan model terhadap hasil klasifikasi. Tampilan hasil klasifikasi posisi 1G pada dashboard dapat dilihat pada Gambar 4.27 di bawah.



Gambar 4.27 Pengujian Posisi Pengelasan 1G
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Berdasarkan Gambar 4.27 di atas, dashboard berhasil menampilkan hasil klasifikasi berupa posisi pengelasan 1G beserta nilai confidence hasil prediksi model LSTM. Nilai confidence menunjukkan tingkat keyakinan model dalam mengklasifikasikan posisi pengelasan yang dilakukan oleh pekerja. Untuk mengetahui konsistensi hasil klasifikasi, dilakukan pengujian sebanyak 10 kali pada posisi 1G. Hasil pengujian tersebut disajikan pada Tabel 4.20 di bawah.

Tabel 4.20 Pengujian Posisi Pengelasan 1G secara *Real-Time*


No	<i>Actual Position</i>	<i>Predicted Position</i>	<i>Confidence(%)</i>
1	1G	1G	60
2	1G	1G	71,1
3	1G	1G	84,4
4	1G	1G	98,8
5	1G	1G	99.9
6	1G	1G	99.9
7	1G	1G	100
8	1G	1G	100

No	<i>Actual Position</i>	<i>Predicted Position</i>	<i>Confidence(%)</i>
9	1G	1G	100
10	1G	1G	100
Rata Rata			91,41

(Sumber : Dokumentasi Pribadi Penulis,2026)

Berdasarkan hasil pengujian yang disajikan pada Tabel 4.20, model LSTM berhasil mengklasifikasikan seluruh data uji pada posisi pengelasan 1G dengan hasil prediksi yang sesuai. Nilai *confidence* yang diperoleh pada setiap percobaan menunjukkan tingkat keyakinan model terhadap hasil klasifikasi yang dihasilkan. Berdasarkan 10 kali pengujian, diperoleh rata-rata nilai confidence sebesar 91,41%. Hasil tersebut menunjukkan bahwa model LSTM memiliki tingkat keyakinan yang tinggi dalam mengenali pola gerakan pada posisi pengelasan 1G. Meskipun terdapat sedikit variasi nilai *confidence* antarpercobaan, seluruh hasil prediksi tetap mengarah pada kelas 1G sehingga menunjukkan bahwa model mampu melakukan klasifikasi secara konsisten pada posisi tersebut.

Selanjutnya, dilakukan pengujian pada posisi pengelasan 2G untuk mengevaluasi kemampuan model LSTM dalam mengklasifikasikan posisi tersebut secara real-time. Proses pengujian hasil klasifikasi posisi 2G pada dashboard ditunjukkan pada Gambar 4.28.



Gambar 4.28 Pengujian Posisi Pengelasan 2G
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Berdasarkan Gambar 4.28, dashboard berhasil menampilkan hasil klasifikasi posisi pengelasan 2G beserta nilai *confidence* yang dihasilkan oleh model LSTM secara real-time. Untuk mengetahui konsistensi hasil klasifikasi pada posisi 2G, dilakukan pengujian sebanyak 10 kali. Hasil pengujian berupa nilai *confidence* pada setiap percobaan disajikan pada Tabel 4.21.

Tabel 4.21 Pengujian Posisi Pengelasan 2G secara *Real-Time*

No	<i>Actual Position</i>	<i>Predicted Position</i>	<i>Confidence(%)</i>
1	2G	2G	74.3
2	2G	2G	70
3	2G	2G	79,5
4	2G	2G	93.4
5	2G	2G	96.8
6	2G	2G	95.4
7	2G	2G	98.1
8	2G	2G	98.1
9	2G	2G	99
10	2G	2G	98.1
Rata Rata			90,27

(Sumber : Dokumentasi Pribadi Penulis,2026)

Berdasarkan hasil pengujian yang disajikan pada Tabel 4.21, model LSTM mampu mengklasifikasikan posisi pengelasan 2G dengan baik pada seluruh percobaan yang dilakukan. Hal tersebut ditunjukkan oleh hasil prediksi yang sesuai dengan posisi sebenarnya pada setiap percobaan. Berdasarkan 10 kali pengujian, diperoleh rata-rata nilai *confidence* sebesar 90,27%, yang menunjukkan bahwa model memiliki tingkat keyakinan yang tinggi dalam mengenali pola gerakan pada posisi pengelasan 2G. Meskipun terdapat sedikit variasi nilai *confidence* antarpercobaan, hasil prediksi tetap konsisten mengarah pada kelas 2G sehingga menunjukkan bahwa model mampu melakukan klasifikasi secara stabil.

Selanjutnya, dilakukan pengujian pada posisi pengelasan 3G untuk mengevaluasi kemampuan model LSTM dalam mengklasifikasikan posisi tersebut secara real-time. Pada pengujian ini, pekerja melakukan aktivitas pengelasan pada posisi 3G, kemudian data pergerakan yang diperoleh dari sensor IMU diproses oleh model LSTM untuk menghasilkan prediksi posisi pengelasan beserta nilai *confidence*. Hasil klasifikasi tersebut selanjutnya ditampilkan secara langsung pada dashboard monitoring sebagai informasi yang dapat diamati oleh pengguna. Proses pengujian hasil klasifikasi posisi 3G pada dashboard ditunjukkan pada Gambar 4.29.



Gambar 4.29 Pengujian Posisi Pengelasan 3G
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Berdasarkan Gambar 4.29, dashboard berhasil menampilkan hasil klasifikasi posisi pengelasan 3G beserta nilai *confidence* yang dihasilkan oleh model LSTM secara real-time. Untuk mengetahui konsistensi hasil klasifikasi pada posisi 3G, dilakukan pengujian sebanyak 10 kali. Hasil pengujian berupa nilai *confidence* pada setiap percobaan disajikan pada Tabel 4.22.

Tabel 4.22 Pengujian Posisi Pengelasan 3G secara *Real-Time*

No	<i>Actual Position</i>	<i>Predicted Position</i>	<i>Confidence(%)</i>
1	3G	3G	65,1
2	3G	3G	79,3
3	3G	3G	90,1
4	3G	3G	90,1
5	3G	3G	90,1
6	3G	3G	97
7	3G	3G	99,8
8	3G	3G	99,8
9	3G	3G	99,8
10	3G	3G	99,8
Rata Rata			91,09

(Sumber : Dokumentasi Pribadi Penulis,2026)

Berdasarkan hasil pengujian yang disajikan pada Tabel 4.22, model LSTM mampu mengklasifikasikan posisi pengelasan 3G dengan baik pada seluruh percobaan yang dilakukan. Seluruh hasil prediksi yang ditampilkan pada dashboard sesuai dengan posisi pengelasan sebenarnya. Berdasarkan 10 kali pengujian, diperoleh rata-rata nilai *confidence* sebesar 91,09%, yang menunjukkan bahwa

model memiliki tingkat keyakinan yang tinggi dalam mengenali pola gerakan pada posisi pengelasan 3G. Meskipun terdapat sedikit variasi nilai *confidence* pada setiap percobaan, hasil prediksi tetap konsisten mengarah pada kelas 3G sehingga menunjukkan bahwa model mampu melakukan klasifikasi secara stabil.

Selanjutnya, dilakukan pengujian pada posisi pengelasan 4G untuk mengevaluasi kemampuan model LSTM dalam mengklasifikasikan posisi tersebut secara real-time. Pada pengujian ini, pekerja melakukan aktivitas pengelasan pada posisi 4G, kemudian data pergerakan yang diperoleh dari sensor IMU diproses oleh model LSTM untuk menghasilkan prediksi posisi pengelasan beserta nilai *confidence*. Hasil klasifikasi tersebut selanjutnya ditampilkan secara langsung pada dashboard monitoring sebagai informasi yang dapat diamati oleh pengguna. Proses pengujian hasil klasifikasi posisi 4G pada dashboard ditunjukkan pada Gambar 4.30.



Gambar 4.30 Pengujian Posisi Pengelasan 4G
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Berdasarkan Gambar 4.30, dashboard berhasil menampilkan hasil klasifikasi posisi pengelasan 4G beserta nilai *confidence* yang dihasilkan oleh model LSTM secara *real-time*. Tampilan tersebut menunjukkan bahwa hasil prediksi dapat diterima dan ditampilkan oleh sistem dengan baik selama proses pengujian berlangsung, sehingga pengguna dapat mengetahui posisi pengelasan yang terdeteksi beserta tingkat keyakinan model terhadap hasil tersebut. Selain itu, tampilan hasil klasifikasi pada dashboard menunjukkan bahwa proses pengiriman dan pengolahan data dapat berlangsung secara berkelanjutan selama aktivitas pengelasan dilakukan. Untuk mengetahui konsistensi hasil klasifikasi pada posisi 4G, dilakukan pengujian sebanyak 10 kali. Hasil pengujian berupa nilai *confidence* pada setiap percobaan disajikan pada Tabel 4.23.

Tabel 4.23 Pengujian Posisi Pengelasan 4G secara *Real-Time*

No	<i>Actual Position</i>	<i>Predicted Position</i>	<i>Confidence(%)</i>
1	4G	4G	67,7
2	4G	4G	88,1
3	4G	4G	95,5
4	4G	4G	99,4
5	4G	4G	99,7
6	4G	4G	100
7	4G	4G	100
8	4G	4G	100
9	4G	4G	100
10	4G	4G	100
Rata Rata			95,04

(Sumber : Dokumentasi Pribadi Penulis,2026)


Berdasarkan hasil pengujian yang disajikan pada Tabel 4.23, model LSTM mampu mengklasifikasikan posisi pengelasan 4G dengan baik pada seluruh percobaan yang dilakukan. Seluruh hasil prediksi yang ditampilkan pada dashboard sesuai dengan posisi pengelasan sebenarnya. Berdasarkan 10 kali pengujian, diperoleh rata-rata nilai *confidence* sebesar 95,04%, yang menunjukkan bahwa model memiliki tingkat keyakinan yang sangat tinggi dalam mengenali pola gerakan pada posisi pengelasan 4G. Meskipun terdapat sedikit variasi nilai *confidence* pada setiap percobaan, seluruh hasil prediksi tetap konsisten mengarah pada kelas 4G sehingga menunjukkan bahwa model mampu melakukan klasifikasi secara stabil.

Secara keseluruhan, hasil pengujian klasifikasi pada dashboard menunjukkan bahwa model LSTM mampu mengklasifikasikan keempat posisi pengelasan, yaitu 1G, 2G, 3G, dan 4G, dengan tingkat keyakinan yang tinggi. Berdasarkan hasil pengujian sebanyak 10 kali pada setiap kelas, diperoleh rata-rata nilai *confidence* sebesar 91,41% untuk posisi 1G, 90,27% untuk posisi 2G, 91,09% untuk posisi 3G, dan 95,04% untuk posisi 4G. Hasil tersebut menunjukkan bahwa sistem mampu mengenali pola pergerakan pada setiap posisi pengelasan secara real-time serta menampilkan hasil klasifikasi pada dashboard dengan baik. Dengan

demikian, integrasi antara sensor IMU, ESP32, server, model LSTM, basis data, dan dashboard monitoring telah berjalan sesuai dengan fungsinya sehingga sistem dapat digunakan untuk mendukung pemantauan aktivitas pengelasan secara real-time.

4.9.3 Pengujian *Latency* Sistem

Pengujian latency sistem seperti yang tersaji pada gambar 4.31 di bawah dilakukan untuk mengetahui waktu yang dibutuhkan sistem dalam menampilkan hasil klasifikasi secara real-time sejak data mulai diproses hingga hasil prediksi ditampilkan pada dashboard. Pengujian dilakukan menggunakan metode *frame-by-frame* dengan memanfaatkan rekaman video yang diambil menggunakan kamera iPhone 13 mini. Video direkam dengan resolusi 4K dan *frame rate* 60 FPS sehingga setiap perubahan tampilan pada dashboard dapat diamati secara rinci. Selanjutnya, selisih jumlah frame antara saat proses dimulai hingga hasil klasifikasi muncul dihitung, kemudian dikonversikan menjadi satuan waktu. Pengujian dilakukan sebanyak 10 kali untuk memperoleh nilai latency yang merepresentasikan performa sistem secara keseluruhan.



Gambar 4.31 Pengujian *Latency* Sistem
(Sumber: Dokumentasi Pribadi Penulis, 2026)

Latency dihitung berdasarkan selisih jumlah frame yang diperoleh dari hasil pengamatan video. Persamaan yang digunakan adalah sebagai berikut.

$$L = \frac{\Delta F}{FPS} \quad (4.19)$$

Keterangan:

- L = Latency (detik)
- ΔF = Selisih jumlah frame

- FPS = Frame rate video (frame per second)

Apabila nilai latency ingin dinyatakan dalam satuan milidetik, maka digunakan persamaan berikut.

$$L_{ms} = \frac{\Delta F}{FPS} \times 1000 \quad (4.20)$$

Keterangan:

- L_{ms} = Latency (ms)
- ΔF = Selisih jumlah frame
- FPS = Frame rate video (frame per second)

Berdasarkan Persamaan (4.) dan Persamaan (4.), nilai latency pada setiap pengujian dihitung berdasarkan selisih jumlah frame yang diperoleh dari hasil pengamatan video menggunakan metode *frame-by-frame*. Selanjutnya, hasil perhitungan latency dari 10 kali pengujian disajikan pada Tabel 4.24 di bawah.


Tabel 4.24 Pengujian *Latency* Sistem

No	Jumlah Frame (ΔF)	FPS	Latency (ms)	Latency (s)
1	2 Frame	60	33,33	0,03333
2	2 Frame	60	33,33	0,03333
3	2 Frame	60	33,33	0,03333
4	2 Frame	60	33,33	0,03333
5	2 Frame	60	33,33	0,03333
6	2 Frame	60	33,33	0,03333
7	2 Frame	60	33,33	0,03333
8	2 Frame	60	33,33	0,03333
9	2 Frame	60	33,33	0,03333
10	2 Frame	60	33,33	0,03333
Rata-rata			33,33	0,03333

(Sumber : Dokumentasi Pribadi Penulis, 2026)

Berdasarkan hasil pengujian yang disajikan pada Tabel 4.24 di atas dan divisualisasikan pada Gambar 4.32 di bawah, nilai *latency* sistem menunjukkan hasil yang konsisten pada seluruh percobaan. Seluruh 10 percobaan menghasilkan *latency* sebesar 33,33 ms, yang setara dengan 2 frame pada video dengan *frame rate* 60 FPS. Hasil tersebut menunjukkan bahwa proses pengiriman data dari perangkat ESP32 menuju server dan proses inferensi model LSTM dapat berlangsung secara

stabil selama pengujian. Nilai *latency* yang konsisten juga menunjukkan bahwa sistem mampu memberikan respons dengan waktu yang relatif cepat dalam melakukan klasifikasi posisi pengelasan. Secara keseluruhan, rata-rata *latency* yang diperoleh adalah sebesar 33,33 ms atau 0,03333 detik. Hasil tersebut menunjukkan bahwa sistem mampu memberikan respons yang cepat dan konsisten dalam melakukan klasifikasi posisi pengelasan serta menampilkan hasilnya pada dashboard secara *real-time*.



Gambar 4.32 Pengujian *Latency* Sistem
(Sumber: Dokumentasi Pribadi Penulis, 2026)

(Halaman ini sengaja dikosongkan)

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil perancangan, implementasi, dan pengujian sistem klasifikasi posisi pengelasan (*welding position*) berbasis multi-sensor *Inertial Measurement Unit* (IMU) menggunakan metode *Long Short-Term Memory* (LSTM), maka dapat diambil beberapa kesimpulan sebagai berikut.

1. Telah berhasil dirancang dan diimplementasikan sistem klasifikasi posisi pengelasan berbasis sensor IMU ICM-20948 dan ESP32 yang mampu melakukan akuisisi, pengiriman, pengolahan, dan visualisasi data secara *real-time*. Dataset yang diperoleh sebanyak 168.740 data mentah dari empat kelas, kemudian diproses menggunakan *sliding window* menjadi 3.368 sampel, yang terdiri atas 2.694 data *training* dan 674 data *testing*.
2. Model LSTM berhasil mengklasifikasikan empat posisi pengelasan, yaitu 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*) menggunakan 9 fitur sensor yang terdiri atas accelerometer, gyroscope, dan magnetometer. Hasil pengujian menghasilkan *accuracy* 96%, *macro average precision* 98%, *recall* 95%, dan *F1-score* 96%.
3. Pada pengujian *real-time*, sistem menghasilkan rata-rata *confidence* sebesar 91,41% untuk 1G, 90,27% untuk 2G, 91,09% untuk 3G, dan 95,04% untuk 4G. Selain itu, sistem memiliki rata-rata *latency* sebesar 33,00 ms (0,033 detik). Hasil tersebut menunjukkan bahwa sistem mampu melakukan klasifikasi dan menampilkan hasil prediksi posisi pengelasan pada dashboard secara *real-time* dengan tingkat keyakinan dan respons yang baik.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut.

1. Menambah jumlah responden dan variasi data pengelasan pada setiap posisi 1G (*flat*), 2G (*horizontal*), 3G (*vertical*), dan 4G (*overhead*). Dengan jumlah data yang lebih banyak dan beragam, model *Long Short-Term Memory* (LSTM) diharapkan mampu mempelajari karakteristik pergerakan tangan welder secara

lebih optimal sehingga meningkatkan kemampuan generalisasi dan performa klasifikasi.

2. Mengembangkan sistem monitoring berbasis *cloud server* sehingga dashboard tidak hanya dapat diakses melalui jaringan lokal (*localhost*), tetapi juga melalui jaringan internet. Dengan demikian, proses monitoring aktivitas welder dapat dilakukan dari berbagai lokasi secara *real-time*, sehingga lebih sesuai untuk implementasi di lingkungan industri.
3. Melakukan pengujian sistem pada lingkungan kerja yang lebih beragam, seperti kondisi area kerja, dan karakteristik *welder* yang berbeda. Pengujian tersebut bertujuan untuk mengevaluasi kestabilan dan keandalan sistem ketika diterapkan pada kondisi operasional yang sesungguhnya, sehingga hasil penelitian dapat lebih merepresentasikan kebutuhan di lingkungan industri.

DAFTAR PUSTAKA

- Adriansyah, S., Nurfuha, U. M., & Giffari, A. (2026). *Performance Analysis of MQTT and HTTP Protocols on Low- Power ESP32 Devices for IoT Applications*. 4(1), 38–45.
- Afida, L. N. I., Bachtiar, F. A., & Cholissodin, I. (2024). Klasifikasi Aktivitas Manusia Menggunakan Metode Long Short-Term Memory. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 11(2), 357–368.
<https://doi.org/10.25126/jtiik.20241127060>
- Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Use of Python as a Programming Language for Machine Learning and Deep Learning. *Scientific Work of Students on the Belief in Monotheism (KARIMAH TAUHID)*, 2(1), 1–6.
- Carlos, W. C., Copetti, A., Bertini, L., Moreira, L. B., & Gomes, O. de S. M. (2024). Human activity recognition: an approach 2D CNN-LSTM to sequential image representation and processing of inertial sensor data. *AIMS Bioengineering*, 11(4), 527–560. <https://doi.org/10.3934/bioeng.2024024>
- Digo, E., Pastorelli, S., & Gastaldi, L. (2022). *A Narrative Review on Wearable Inertial Sensors for Human Motion Tracking in Industrial Scenarios*.
- Espinosa-Gavira, M. J., Agüera-Pérez, A., Palomares-Salas, J. C., Sierra-Fernandez, J. M., Remigio-Carmona, P., & González de-La-Rosa, J. J. (2024). Characterization and Performance Evaluation of ESP32 for Real-time Synchronized Sensor Networks. *Procedia Computer Science*, 237(2022), 261–268. <https://doi.org/10.1016/j.procs.2024.05.104>
- Estriyanto, Y., Komarudin, K., Towip, T., Saputra, T. W., & Widiastuti, I. (2024). Mewujudkan Pembelajaran Kejuruan yang Nyaman: Implementasi Kaidah Ergonomi dalam Praktek Pengelasan di SMK Negeri 1 Purworejo. *DEDIKASI: Community Service Reports*, 6(2), 96–107.
<https://doi.org/10.20961/dedikasi.v6i2.80412>

- He, Z., Sun, Y., & Zhang, Z. (2024). Human Activity Recognition Based on Deep Learning Regardless of Sensor Orientation. *Applied Sciences (Switzerland)*, 14(9). <https://doi.org/10.3390/app14093637>
- Jaramillo, I. E., Chola, C., Jeong, J. G., Oh, J. H., Jung, H., Lee, J. H., Lee, W. H., & Kim, T. S. (2023). Human Activity Prediction Based on Forecasted IMU Activity Signals by Sequence-to-Sequence Deep Neural Networks. *Sensors*, 23(14), 1–16. <https://doi.org/10.3390/s23146491>
- Jaramillo, I. E., Jeong, J. G., Lopez, P. R., Lee, C. H., Kang, D. Y., Ha, T. J., Oh, J. H., Jung, H., Lee, J. H., Lee, W. H., & Kim, T. S. (2022). Real-Time Human Activity Recognition with IMU and Encoder Sensors in Wearable Exoskeleton Robot via Deep Learning Networks. *Sensors*, 22(24). <https://doi.org/10.3390/s22249690>
- Karlina, F. H., Sunarno, Waruwu, M. M., & Wijaya, R. (2021). Study of Several Types of Lithium-polymer Batteries with 3s Battery Management System. *IOP Conference Series: Earth and Environmental Science*, 927(1). <https://doi.org/10.1088/1755-1315/927/1/012023>
- Maharja, R., Faradisha, J., & Panggeleng, A. M. F. (2022). Safety Behaviour Tendency Among Welders By Utilising Personal Protective Equipment. *Al-Sihah: The Public Health Science Journal*, 192–201. <https://doi.org/10.24252/al-sihah.v14i2.33279>
- Malashin, I., Tynchenko, V., Gantimurov, A., Nelyub, V., & Borodulin, A. (2024). Applications of Long Short-Term Memory (LSTM) Networks in Polymeric Sciences: A Review. *Polymers*, 16(18), 1–44. <https://doi.org/10.3390/polym16182607>
- Pangarkar, A. P., Gawande, P. G., & Shabadi, S. (2025). A Comprehensive Analysis of ESP32 Microcontroller for IoT Applications. *International Journal of Novel Research and Development*, 10(10), 501–505.
- Penerapan, T., Bidang, K., Fabrikasi, P., & Pada, L. (2024). *Al-Tamimi Kesmas*. 13, 251–260.

- Pradani, H. N., & Mahananto, F. (2021). Studi Literatur Human Activity Recognition (HAR) Menggunakan Sensor Inersia. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(6), 1193–1206.
<https://doi.org/10.29207/resti.v5i6.3665>
- Pribadi, T. W., & Shinoda, T. (2022). Analysis of Wrist Hand Motion for Monitoring of Basic Welder Training using Wearable Sensors. *IOP Conference Series: Earth and Environmental Science*, 972(1).
<https://doi.org/10.1088/1755-1315/972/1/012010>
- Prisco, G., Pirozzi, M. A., Santone, A., Esposito, F., Cesarelli, M., Amato, F., & Donisi, L. (2025). *Validity of Wearable Inertial Sensors for Gait Analysis : A Systematic Review*. 1–24.
- Rivas-Caicedo, J. L., Saldaña-Aristizabal, L., Niño-Tejada, K., & Patarroyo-Montenegro, J. F. (2025). A Multi-Sensor Dataset for Human Activity Recognition Using Inertial and Orientation Data. *Data*, 10(8), 1–11.
<https://doi.org/10.3390/data10080129>
- Saputra, R., Kurnia, D. A., & Wijaya, Y. A. (2025). *The Effectiveness of Dropout Layers in LSTM Architecture for Reducing Overfitting in Sony Stock Prediction*. 7(2), 77–85.
- Sinha, K. P., Kumar, P., & Ghosh, R. (2023). Human Activity Recognition using LSTM with depth data. *International Journal of Intelligent Systems and Applications in Engineering*, 11(10s), 535–542.
- Suheri Jumartika, Abd. Gafur, & Rahman. (2021). Analisis Risiko Pada Pekerja Pengelasan (Welding) di PT. Industri Kapal Indonesia (Persero) Kota Makassar. *Window of Public Health Journal*, 2(2), 328–338.
<https://doi.org/10.33096/woph.v2i2.162>
- Sulaiman, M., Kumar, D., Tukur, S., Mokoyo, M., & Saleh, A. (2024). Optimization of TIG welding parameters for enhanced mechanical properties of Al 7075 weldments. *Kathmandu University Journal of Science, Engineering and Technology*, 18(2).

<https://doi.org/10.70530/kuset.v18i2.577>

- Utomo, C. W., & Yunus, Y. (2021). Pengaruh posisi pengelasan terhadap kekuatan tarik dan tekuk pada sambungan Las Baja ST 41. *Jurnal Teknik Mesin UNESA*, 9(2), 1–4. <https://ejournal.unesa.ac.id/index.php/jtm-unesa/article/view/39923>
- Verianto, E. (2024). *MENCEGAH OVERFITTING PADA MODEL PREDIKSI*. 9(2), 195–204.
- Virmansyah, V. M., Pribadi, T. W., & Baihaqi, I. (2024). Deep Learning CNN-LSTM Approach for Identifying Welder's Hand Motion Gestures Using Wearable Sensors. *IOP Conference Series: Earth and Environmental Science*, 1423(1). <https://doi.org/10.1088/1755-1315/1423/1/012036>

LAMPIRAN

Lampiran 1. *Sample Dataset* Posisi Pengelasan 1G

time	onds_elap	accel_x	accel_y	accel_z	gyro_x	gyro_y	gyro_z	mag_x	mag_y	mag_z	label
1,76E+18	0,088665	0,348371	-0,06032	-0,09774	-0,04844	-0,06068	0,052395	19,60913	32,43105	-30,6236	1G
1,76E+18	0,108547	0,141326	-0,18854	-0,08864	-0,04228	-0,01002	0,007898	19,6801	32,51582	-30,5481	1G
1,76E+18	0,12843	0,190371	-0,09547	-0,17517	-0,0595	-0,00024	0,024972	19,58327	32,36682	-30,4717	1G
1,76E+18	0,148313	-0,15352	0,000969	-0,24639	-0,06183	0,044622	0,001663	19,76631	32,43665	-30,3577	1G
1,76E+18	0,168195	-0,05197	-0,17147	-0,03588	-0,06829	-0,03059	0,006387	19,82339	32,51042	-30,4487	1G
1,76E+18	0,188078	0,032555	-0,08765	0,128551	-0,08907	-0,05945	0,000133	19,76497	32,54019	-30,5635	1G
1,76E+18	0,207961	-0,06875	-0,18442	0,079518	-0,08529	-0,05623	-0,01812	19,81549	32,533	-30,0965	1G
1,76E+18	0,227844	0,026613	0,077732	0,131962	-0,07787	-0,04278	-0,00778	19,75729	32,60435	-30,0658	1G
1,76E+18	0,247726	-0,32839	-0,11689	0,102491	-0,08823	0,011381	0,016787	19,71193	32,80988	-30,3009	1G
1,76E+18	0,267609	-0,31282	-0,21226	0,140745	-0,08548	-0,0041	0,06213	19,84976	32,93602	-30,2436	1G
1,76E+18	0,287492	-0,04117	-0,127	0,283383	-0,10007	-0,13947	0,060356	19,80721	32,89201	-30,369	1G
1,76E+18	0,307374	0,079453	-0,25769	0,273428	-0,11713	-0,25434	0,080794	19,79236	33,03211	-30,216	1G
1,76E+18	0,327257	0,191147	-0,1924	0,340053	-0,13075	-0,32844	0,123765	19,62524	33,00417	-30,3142	1G
1,76E+18	0,34714	0,232122	-0,2976	0,354427	-0,16362	-0,44057	0,143683	19,38275	33,02789	-30,2992	1G
1,76E+18	0,367022	0,181822	-0,42924	-0,09738	-0,11503	-0,14312	0,288901	19,4456	33,00757	-30,2975	1G
1,76E+18	0,386905	-1,14572	-0,58657	-0,11422	-0,08363	-0,05184	0,351081	19,14067	32,82439	-30,4314	1G
1,76E+18	0,406788	-0,75541	-0,38868	-0,00294	-0,07978	-0,02799	0,482043	19,46008	32,81445	-30,1212	1G
1,76E+18	0,426671	-0,77025	-0,46689	-0,0066	-0,11139	-0,11004	0,571673	19,86038	32,65942	-30,0753	1G
1,76E+18	0,446553	-0,48207	-0,96352	0,237205	-0,1907	-0,28191	0,604406	20,0192	32,5444	-30,3432	1G
1,76E+18	0,466436	-0,19151	-1,13543	0,426937	-0,232	-0,2555	0,54537	20,29434	32,46868	-30,2752	1G
1,76E+18	0,486319	-0,54507	-0,59016	-0,0339	-0,29154	-0,29833	0,696189	20,45432	32,29432	-30,057	1G
1,76E+18	0,506201	-0,42411	-0,2921	-0,39188	-0,2341	-0,32338	0,828891	20,5531	32,22399	-30,0058	1G
1,76E+18	0,526084	-0,48447	-0,30813	-0,19034	-0,16703	-0,20643	0,885485	21,07355	31,99478	-30,0102	1G
1,76E+18	0,545967	-0,8306	-0,00125	-0,39614	-0,17526	-0,11321	0,912409	21,45418	31,60673	-29,9475	1G
1,76E+18	0,565849	-0,25423	-0,68567	-0,35299	-0,16772	0,295776	0,951896	22,084	31,48473	-30,0257	1G
1,76E+18	0,585732	-1,22336	-0,45084	-0,26926	-0,15783	0,50874	0,977727	22,8474	31,25202	-30,0018	1G
1,76E+18	0,605615	-0,8464	-0,36095	0,257457	-0,20116	0,482543	0,929256	23,75166	30,7426	-29,3744	1G
1,76E+18	0,625498	-0,28391	-0,35806	0,705068	-0,22042	0,342752	0,891915	24,54465	30,51383	-29,0455	1G
1,76E+18	0,64538	-0,05609	-0,11254	0,5868	-0,24731	0,106897	0,755982	25,12181	30,30453	-29,1039	1G
1,76E+18	0,665263	0,325203	-0,23501	0,727037	-0,39919	-0,25883	0,849454	25,92336	30,17394	-28,7834	1G
1,76E+18	0,685146	0,044652	-0,63328	0,469558	-0,54484	-0,70521	0,659172	26,12883	30,06754	-28,6974	1G
1,76E+18	0,705028	0,947632	-0,05839	0,548075	-0,61844	-1,11582	0,633379	25,84755	30,0659	-28,8758	1G
1,76E+18	0,724911	0,492974	0,231361	0,299126	-0,56897	-1,19326	0,622857	25,65421	30,0575	-29,1079	1G
1,76E+18	0,744794	-0,81392	0,561256	0,108327	-0,5346	-0,69841	0,574938	25,47221	29,99702	-29,5429	1G
1,76E+18	0,764677	-0,95304	0,627387	-0,8858	-0,45277	0,32155	0,35228	25,4476	30,08525	-29,6063	1G
1,76E+18	0,784559	-1,31468	-0,17811	-1,2499	-0,31023	0,90801	0,352667	26,04326	30,14674	-29,0503	1G
1,76E+18	0,804442	-0,62253	0,078534	0,315617	-0,38219	0,363596	0,234884	26,6096	30,35842	-28,296	1G
1,76E+18	0,824325	0,609882	0,727649	1,362171	-0,51751	-0,32738	0,142651	26,96667	30,44145	-27,9935	1G
1,76E+18	0,844207	-0,20974	1,533471	-0,42894	-0,48677	-0,35314	0,172089	26,87466	30,66841	-28,2507	1G
1,76E+18	0,86409	-0,79521	-0,07434	-0,473	-0,52922	-0,51867	0,197303	26,77669	30,82571	-27,9783	1G
1,76E+18	0,883973	0,136976	-0,09847	0,395061	-0,55387	-0,96603	0,02579	26,65808	30,95163	-27,8729	1G
1,76E+18	0,903855	0,204036	0,891211	0,607175	-0,52182	-0,99242	-0,02306	26,12944	31,23125	-28,0014	1G
1,76E+18	0,923738	-0,20036	-0,07564	0,247442	-0,42308	-0,43427	-0,05632	25,76648	31,48695	-28,1412	1G
1,76E+18	0,943621	-0,97933	-1,15259	0,710141	-0,53635	-0,00489	-0,17247	25,41568	31,82769	-28,1038	1G
1,76E+18	0,963504	0,682652	-0,30659	0,565321	-0,55854	0,054534	-0,0417	25,33711	32,11425	-27,5337	1G
1,76E+18	0,983386	0,881314	0,09504	0,523874	-0,52083	-0,44389	-0,10518	25,23283	32,26418	-27,3056	1G
1,76E+18	1,003269	1,944265	0,227709	0,58105	-0,44856	-0,8265	-0,29157	25,02254	32,79359	-27,3138	1G
1,76E+18	1,023152	1,246214	1,319083	-0,23972	-0,48051	-0,86674	-0,41427	24,32426	33,18964	-27,3844	1G
1,76E+18	1,043034	0,145199	-0,49762	0,357645	-0,46958	0,184264	-0,36747	23,81215	33,66278	-27,3826	1G
1,76E+18	1,062917	-2,12864	-1,83906	0,543862	-0,52751	0,064446	-0,64896	23,39626	34,26537	-27,1268	1G
1,76E+18	1,0828	1,194159	-1,38248	0,512287	-0,65495	-0,45189	-0,57599	23,0244	34,72239	-26,4842	1G
1,76E+18	1,102682	2,168345	-1,71927	0,190351	-0,77053	-0,72568	-0,66223	22,40779	35,39975	-26,5524	1G
1,76E+18	1,122565	-0,44838	-1,275	-0,749	-0,78327	-0,41038	-0,69018	21,49065	36,05872	-26,1212	1G
1,76E+18	1,142448	-0,8953	-1,2309	0,720153	-0,80407	-0,26944	-0,7873	20,68941	36,84089	-25,6015	1G
1,76E+18	1,162331	0,731534	-1,50619	0,368535	-0,79821	-0,18417	-0,79082	19,98369	37,36968	-25,0706	1G
1,76E+18	1,182213	0,519366	-1,4316	0,943422	-0,83115	-0,41749	-0,79813	19,27806	38,19286	-24,5342	1G
1,76E+18	1,202096	0,584789	-1,26371	0,841076	-0,78154	-0,06835	-0,81502	18,53818	38,81019	-24,1061	1G
1,76E+18	1,221979	-0,26304	-1,26873	1,172954	-0,77317	-0,21882	-0,98758	17,64093	39,43376	-23,2665	1G
1,76E+18	1,241861	1,252924	-1,15205	1,227989	-0,75106	-0,41445	-1,16489	16,58994	40,08706	-22,708	1G
1,76E+18	1,261744	0,337067	-1,48698	1,434242	-0,72747	-0,96336	-1,60617	15,19789	40,90964	-22,3033	1G
1,76E+18	1,281627	1,07145	-0,91393	1,416154	-0,73089	-1,79373	-1,90456	13,32045	41,81571	-21,9331	1G

1,76E+18	1,301509	1,392595	-0,29492	1,255492	-0,74707	-1,62922	-1,19216	10,97078	42,52068	-21,6096	1G
1,76E+18	1,321392	-0,29865	-0,95072	0,303303	-0,67797	-1,15765	-1,34059	9,247711	42,99508	-21,5497	1G
1,76E+18	1,341275	-0,31947	-1,17986	1,239636	-0,757	-0,82401	-1,30774	7,644257	43,71249	-20,905	1G
1,76E+18	1,361157	-0,76058	0,18802	0,32829	-0,92493	-1,2199	-1,6436	7,21608	43,95182	-20,3581	1G
1,76E+18	1,38104	0,279838	0,357746	-0,49378	-0,98816	-1,21888	-1,32262	5,096985	44,57745	-19,591	1G
1,76E+18	1,400923	0,456406	-0,33403	-0,8947	-1,03412	-1,20343	-1,10633	3,257431	45,16477	-18,5554	1G
1,76E+18	1,420806	0,385376	-1,43395	-0,43533	-1,15849	-1,23569	-1,08099	1,869461	45,45531	-17,4578	1G
1,76E+18	1,440688	-0,06867	-0,68326	0,242589	-1,21434	-1,44551	-1,04557	0,478302	45,6353	-16,2631	1G
1,76E+18	1,460571	1,382602	-1,28488	2,224803	-1,20297	-1,32479	-1,02879	-1,04759	46,03042	-15,072	1G
1,76E+18	1,480454	1,999993	-1,09554	1,79022	-1,27095	-1,69324	-1,00088	-2,52246	46,30534	-13,3737	1G
1,76E+18	1,500336	1,686492	-0,25209	0,836565	-1,14626	-1,71778	-1,22618	-3,88048	46,41782	-11,7731	1G
1,76E+18	1,520219	1,442436	-0,43566	0,793122	-0,96333	-1,76437	-1,54879	-5,31708	46,40169	-10,3606	1G
1,76E+18	1,540102	-1,00178	0,643542	5,165174	-1,06115	-1,17889	-1,55788	-7,27119	46,17272	-8,91345	1G
1,76E+18	1,559984	-3,77462	1,662542	-0,04207	-1,15853	-1,09073	-1,54409	-8,88097	45,88836	-7,48023	1G
1,76E+18	1,579867	-3,17999	0,59485	-1,87132	-1,36197	-1,68764	-1,33546	-10,2918	45,59941	-6,20441	1G
1,76E+18	1,59975	2,261819	-0,37962	-0,44531	-1,44806	-2,41919	-0,66683	-11,5721	45,17289	-4,12986	1G
1,76E+18	1,619632	3,143037	-1,42833	-1,06507	-1,83299	-2,84797	-0,42101	-12,0104	45,07637	-1,85322	1G
1,76E+18	1,639515	-0,58841	-0,46404	-1,35982	-1,77453	-1,81159	-1,45671	-12,6393	44,68135	0,916542	1G
1,76E+18	1,659398	-0,80517	0,111372	-0,84595	-1,66633	-0,91632	-0,98511	-13,662	43,94246	2,961826	1G
1,76E+18	1,67928	-1,73734	-1,96566	1,010776	-1,72626	-1,35209	-0,7721	-14,1024	43,19178	5,002911	1G
1,76E+18	1,699164	-3,0962	0,090196	-0,4101	-1,41339	-0,795	-0,67537	-14,4693	42,65306	6,812824	1G
1,76E+18	1,719046	-1,9637	1,111869	0,755622	-1,20184	-0,35655	-0,5934	-14,7556	42,02411	8,109437	1G
1,76E+18	1,738929	-1,56543	-0,30857	-0,42558	-1,35085	-0,61941	-0,53782	-14,9273	41,34058	9,62327	1G
1,76E+18	1,758811	0,437035	0,198867	-0,0138	-1,38454	-0,25865	-0,69409	-15,096	40,66998	10,82344	1G
1,76E+18	1,778695	1,772301	0,183967	1,38734	-1,58162	-0,76271	-0,67133	-15,305	39,8042	12,33201	1G
1,76E+18	1,798577	1,377023	-0,00515	0,988564	-1,64859	-1,00078	-0,75198	-15,3734	38,88255	14,12323	1G
1,76E+18	1,818459	-0,45855	0,266641	0,758252	-1,68049	-1,49054	-0,83492	-15,4781	37,76982	15,51605	1G
1,76E+18	1,838343	0,555604	-0,12697	0,972132	-1,6851	-1,8229	-0,87966	-15,3873	37,41651	16,35013	1G
1,76E+18	1,858225	0,996055	-0,45819	1,107304	-1,64857	-1,56256	-0,85898	-15,0199	36,31351	17,84369	1G
1,76E+18	1,878107	0,008732	-1,30894	0,600237	-1,47688	-0,89483	-0,9275	-14,8408	35,04771	19,74525	1G
1,76E+18	1,89799	0,140813	-0,99554	-0,10626	-1,25348	-0,30363	-0,87548	-14,5669	34,02526	20,9341	1G
1,76E+18	1,917874	1,311431	-1,10613	0,285512	-1,17945	-0,63203	-0,96378	-14,6107	32,82048	21,71344	1G
1,76E+18	1,937756	1,654324	-1,12268	0,881258	-1,19383	-1,05134	-0,94706	-14,5186	31,94978	22,33128	1G
1,76E+18	1,957638	1,626241	-2,16614	0,522052	-1,39299	-1,8832	-0,71194	-14,071	30,72298	23,04873	1G
1,76E+18	1,977521	1,404239	-1,4236	0,68022	-1,63476	-2,8444	-0,69505	-12,9602	29,58496	24,16745	1G
1,76E+18	1,997404	-0,08902	-0,37692	0,204869	-1,59186	-1,86541	-0,75939	-11,7016	28,48582	25,50063	1G
1,76E+18	2,017286	-0,92584	-0,39153	-1,26632	-1,57872	-1,17786	-1,09329	-10,5486	27,51285	26,01729	1G
1,76E+18	2,037169	1,160369	-0,80066	-1,32288	-1,5914	-1,35054	-1,12841	-10,0201	26,24027	26,58577	1G
1,76E+18	2,057052	2,42134	-1,27856	-1,19282	-1,3168	-0,98542	-0,47559	-9,51103	24,94954	27,23198	1G
1,76E+18	2,076934	-0,46871	-1,74973	-0,36688	-1,23739	-1,67579	-0,40179	-8,76764	23,82179	27,46719	1G
1,76E+18	2,096817	-4,13266	-2,02643	-0,29324	-1,0371	-2,00133	-0,91759	-7,57721	23,05314	27,53135	1G
1,76E+18	2,1167	-4,52684	1,16738	0,766272	-1,65296	-1,33122	-1,46651	-6,7823	22,09827	27,63914	1G
1,76E+18	2,136583	-4,74449	3,439059	2,278552	-1,59718	-1,10674	-0,9345	-6,28983	21,06313	28,13869	1G
1,76E+18	2,156465	-1,56071	5,446713	0,887185	-1,18038	-1,21306	-0,29203	-5,77922	19,88018	28,24173	1G
1,76E+18	2,176348	0,243794	-0,34477	-0,05227	-1,06036	-2,13448	-0,05736	-4,79706	19,07752	28,17023	1G
1,76E+18	2,196231	0,841339	-1,01652	0,879927	-1,18668	-2,53959	0,058062	-3,47003	18,51545	28,35342	1G
1,76E+18	2,216113	0,35826	1,736285	3,033908	-1,30723	-2,72394	-0,1392	-1,70486	18,01354	28,29303	1G
1,76E+18	2,235996	-2,09726	3,03666	0,399026	-1,25396	-1,69854	-0,11843	-0,047	17,5359	28,33639	1G
1,76E+18	2,255879	-1,02371	0,919311	-1,07779	-0,86609	-0,38819	-0,13292	0,613586	16,80816	28,44497	1G
1,76E+18	2,275761	0,428863	-1,10272	-0,41595	-0,67956	1,004217	-0,16569	0,423538	16,38004	28,41993	1G
1,76E+18	2,295644	-3,05919	-2,33027	1,030746	-0,87813	-0,08492	-0,43293	0,165253	15,94614	28,21661	1G
1,76E+18	2,315528	-0,47682	-0,99522	2,115368	-0,90009	0,231505	-0,83231	0,177628	15,72254	28,18839	1G
1,76E+18	2,335409	1,031281	1,848147	-0,58346	-0,91555	0,570887	-0,7769	-0,05284	15,2836	28,07211	1G
1,76E+18	2,355292	1,160319	-0,02085	-0,89277	-0,99271	1,171224	-0,82373	-0,62485	14,76897	27,88238	1G
1,76E+18	2,375175	0,217205	0,163421	-0,2668	-1,05763	1,390338	-1,00064	-1,54237	14,14911	27,66763	1G
1,76E+18	2,395058	-0,20804	0,824719	-1,13499	-0,99972	1,44265	-1,19954	-2,40918	13,57227	27,53479	1G
1,76E+18	2,41494	-1,34952	-0,12883	0,465308	-0,94195	1,180379	-1,41228	-3,33063	13,00096	27,19104	1G
1,76E+18	2,434823	-1,72539	0,571632	-0,19918	-0,94876	0,318693	-1,40402	-4,09132	12,32506	26,9845	1G
1,76E+18	2,454707	-0,5183	-1,80991	0,761231	-1,04516	0,411811	-0,94958	-4,59151	11,70811	26,65955	1G
1,76E+18	2,474588	1,466098	-0,93912	2,225668	-1,05911	-0,2273	-0,65969	-4,71153	11,00793	26,60394	1G
1,76E+18	2,494471	-0,5885	0,772596	2,848662	-0,90111	-1,28729	-0,70016	-4,80396	10,42175	26,5726	1G
1,76E+18	2,514354	-1,03044	-0,38016	3,192108	-1,16987	-2,98196	-0,07318	-4,02927	10,0921	26,44802	1G

1,76E+18	2,534237	3,84462	-0,75268	3,004125	-1,27065	-4,11789	-0,12972	-2,5522	9,675072	26,49048	1G
1,76E+18	2,554119	2,768255	0,65462	4,393127	-1,20802	-6,15826	0,079476	-0,2032	9,243584	26,81472	1G
1,76E+18	2,574002	0,958734	1,164467	3,834345	-1,0906	-6,17873	0,125346	3,030045	9,125977	26,71256	1G
1,76E+18	2,593885	-3,19705	-0,50117	2,11763	-1,2455	-5,08235	-0,22024	5,964737	9,188873	26,33445	1G
1,76E+18	2,613767	-3,6962	2,525277	-2,92906	-1,41899	-1,78368	0,02116	8,093765	8,72377	25,78186	1G
1,76E+18	2,63365	-9,33515	-0,08603	-2,31842	-0,9612	0,879927	-0,16131	8,69519	8,134201	25,79476	1G
1,76E+18	2,653533	-7,32389	1,773454	-0,21025	-0,65063	2,306643	-0,39557	8,016006	7,622398	25,86806	1G
1,76E+18	2,673415	-3,33516	2,439029	-0,04738	-0,7361	3,208369	0,207345	6,546249	7,13205	26,27841	1G
1,76E+18	2,693298	-0,51049	-2,97821	0,02967	-1,05555	2,321055	-0,0548	4,94014	6,480934	26,41116	1G
1,76E+18	2,713181	-1,62176	0,543792	0,033437	-0,88375	2,175486	0,196817	4,027115	5,752861	26,60162	1G
1,76E+18	2,733063	-2,24356	0,314589	0,270112	-0,7716	2,908013	-0,1271	2,550949	5,108864	27,01647	1G
1,76E+18	2,752946	1,567812	-2,42176	-0,52261	-0,62783	2,216393	-0,13969	1,365448	4,682243	26,72756	1G
1,76E+18	2,772829	7,529353	-0,74658	0,426981	-0,92345	0,004311	0,564145	0,525787	3,918602	26,70514	1G
1,76E+18	2,792712	6,204105	0,054324	3,148505	-0,92587	-1,13488	0,206898	0,270889	3,538383	26,76577	1G
1,76E+18	2,812594	3,001827	1,062741	5,462345	-1,14811	-1,66334	0,373231	0,990036	3,056908	26,19739	1G
1,76E+18	2,832477	0,87652	-3,05235	3,082773	-1,11207	-2,85773	0,590211	1,994247	2,607155	26,29232	1G
1,76E+18	2,85236	-2,91108	-2,43963	1,851499	-0,7832	-2,09408	0,754828	3,128357	2,282051	26,2211	1G
1,76E+18	2,872242	-2,65729	1,341997	-1,56149	-0,64613	-0,92221	0,347614	4,115936	2,030319	26,3243	1G
1,76E+18	2,892125	-3,06192	1,702082	-1,47368	-0,23968	0,934614	-0,05427	4,414993	1,727798	26,18274	1G
1,76E+18	2,912008	1,666263	1,519154	-0,23798	-0,37513	0,772108	0,131052	4,099487	1,732635	26,30751	1G
1,76E+18	2,931891	2,868396	-0,60396	1,318565	-0,49922	-0,56034	0,213915	3,772308	1,589821	26,20258	1G
1,76E+18	2,951773	1,01769	-1,23146	0,541176	-0,56511	-0,97042	0,075969	4,106766	1,377983	26,05275	1G
1,76E+18	2,971656	-2,97755	1,45997	-0,69111	-0,25098	0,648768	-0,26565	4,349564	1,270447	25,7876	1G
1,76E+18	2,991539	-4,71234	-0,09696	-1,19447	-0,09006	2,107648	-0,83263	3,79213	1,087433	25,79351	1G
1,76E+18	3,011421	-0,93604	0,173882	1,358327	0,142499	2,365311	-0,7785	2,835297	1,092598	25,75342	1G
1,76E+18	3,031304	0,56271	-0,12528	2,640027	0,139728	1,242705	-0,73609	1,610611	1,128738	25,75524	1G
1,76E+18	3,051187	2,492683	0,675766	3,333992	0,238515	0,868235	-0,22059	1,034103	1,182877	25,8935	1G
1,76E+18	3,071069	1,455932	1,302701	1,08523	0,21592	0,50994	-0,29615	0,69014	1,444382	25,55702	1G
1,76E+18	3,090952	0,485607	-0,41297	-0,28672	-0,07871	0,112088	-0,37575	0,470352	1,461586	25,67182	1G
1,76E+18	3,110835	-0,18212	-1,27415	-2,8302	-0,19886	-0,51234	-0,42829	0,529953	1,452553	25,56642	1G
1,76E+18	3,130718	-1,68376	0,247249	-2,00355	-0,02203	-0,37824	-0,6495	0,712799	1,489983	25,61789	1G
1,76E+18	3,1506	-0,42385	1,990424	1,91645	0,354991	-0,13201	-0,41474	0,844543	1,561829	25,82355	1G
1,76E+18	3,170483	1,092603	-0,07338	3,990489	0,702416	1,189722	0,235203	0,798859	1,842293	25,58987	1G
1,76E+18	3,190366	-5,32333	-0,60564	1,690833	0,643084	1,143964	0,407174	-0,0352	2,156769	25,6122	1G
1,76E+18	3,210249	-3,60904	-2,67643	-0,71137	0,489855	0,554333	-0,28724	-0,42912	2,514145	25,78818	1G
1,76E+18	3,230131	2,324034	0,61024	-2,07867	0,316601	0,376556	-0,15456	-0,62822	2,629784	25,76382	1G
1,76E+18	3,250014	-0,87511	1,189769	-1,52548	0,551742	1,269192	-0,2842	-1,06856	2,739456	25,57998	1G
1,76E+18	3,269897	0,308007	1,819551	0,293846	0,489813	1,841971	-0,26096	-1,88646	2,872337	25,63472	1G
1,76E+18	3,289779	0,218264	0,175111	-0,31696	0,241165	1,542186	-0,38525	-2,489	2,676643	25,3623	1G
1,76E+18	3,309662	3,24469	-0,85255	-0,07695	-0,25221	0,84695	-0,11309	-3,15804	2,681915	25,44429	1G
1,76E+18	3,329545	3,972473	-0,96499	-0,54776	-0,13149	0,83483	-0,202	-3,72424	2,612015	25,15338	1G
1,76E+18	3,349428	-3,28361	6,618053	0,875824	0,11386	0,709266	-0,68624	-4,18369	2,48774	25,30587	1G
1,76E+18	3,36931	1,508209	-1,65589	2,675327	-0,23167	-1,16489	-0,58514	-4,4055	2,256668	25,39735	1G
1,76E+18	3,389193	4,924738	-2,1609	1,057081	-0,59438	-2,07599	0,728777	-3,88484	2,264893	25,59353	1G
1,76E+18	3,409076	-2,14815	1,916412	-4,244	-0,52047	-1,85994	0,882759	-2,83498	1,944298	25,86873	1G
1,76E+18	3,428958	-7,74225	-2,41648	-3,986	-0,29049	-0,15117	0,491692	-1,90616	1,845337	25,83108	1G
1,76E+18	3,448841	-3,83895	-0,42157	-2,2687	-0,13363	0,625234	-0,18601	-1,75598	1,565208	25,85211	1G
1,76E+18	3,468724	1,925905	-3,45266	1,340253	-0,56296	-0,21315	-0,06373	-2,02663	1,246254	25,65893	1G
1,76E+18	3,488606	0,881764	3,05508	2,041487	-0,51021	-0,31996	-0,30872	-1,98396	0,78289	25,84784	1G
1,76E+18	3,508489	5,108384	1,717214	1,263017	-0,53375	-0,64956	-0,13775	-1,77293	0,373787	25,93196	1G
1,76E+18	3,528372	-0,68394	-1,95708	-2,02313	-0,23396	-0,25265	-0,3462	-1,3221	0,058617	25,76085	1G
1,76E+18	3,548255	-0,97028	-0,47918	-0,79348	-0,07156	-0,1017	-0,16912	-0,97021	-0,20764	26,12325	1G
1,76E+18	3,568137	-0,21346	0,364202	0,997632	-0,14327	-0,13937	-0,03623	-0,85214	-0,41311	26,22849	1G
1,76E+18	3,58802	3,225272	1,5725	1,884496	-0,22221	-0,81801	0,302255	-0,67461	-0,52762	26,16638	1G
1,76E+18	3,607903	2,304593	0,573786	3,144991	-0,36536	-1,01537	0,369686	-0,18163	-0,7512	26,50837	1G
1,76E+18	3,627786	-0,11419	-0,28849	0,598641	-0,31011	-0,3836	0,6028	0,366058	-0,77744	26,43447	1G
1,76E+18	3,647668	-3,05832	-0,15765	-3,55762	0,111581	0,027622	0,349709	0,52095	-0,85616	26,52828	1G
1,76E+18	3,667551	-1,88707	-0,81149	0,105866	0,149024	0,255082	0,218774	0,595703	-0,93117	26,71303	1G
1,76E+18	3,687434	0,940584	0,066497	-0,64077	-0,00882	0,018497	0,129703	0,528168	-0,90027	26,60745	1G
1,76E+18	3,707316	2,752187	-1,18418	0,946806	-0,09811	-0,23187	0,164388	0,603638	-1,13358	26,59325	1G
1,76E+18	3,727199	-0,12567	-1,40072	-1,32429	0,18907	0,561493	0,056694	0,514297	-1,16333	26,4163	1G
1,76E+18	3,747082	-4,54507	1,032093	-1,11223	0,162793	1,200607	0,086136	0,223343	-1,05928	26,35271	1G

Lampiran 2. Sample Dataset Posisi Pengelasan 2G

time	onds_elap	accel_x	accel_y	accel_z	gyro_x	gyro_y	gyro_z	mag_x	mag_y	mag_z	label
1,76E+18	0,076725	0,11827	0,054276	-0,09986	-0,00018	-0,03364	-0,02682	27,8615	22,26265	-31,2307	2G
1,76E+18	0,096609	-0,30377	-0,06358	-0,03379	0,002983	-0,00133	-0,02334	27,88309	22,26749	-31,3028	2G
1,76E+18	0,116491	-0,27625	-0,02544	0,104595	-0,00125	0,043667	-0,00082	27,8345	22,19406	-31,548	2G
1,76E+18	0,136374	-0,05109	-0,10992	0,041634	-0,00406	0,050642	0,025824	27,79042	22,18719	-31,6973	2G
1,76E+18	0,156257	0,026	0,03307	-0,01243	0,003409	0,067046	0,017174	27,99699	22,16373	-31,5014	2G
1,76E+18	0,17614	0,287374	0,223473	0,094178	0,010882	-0,10059	-0,01387	28,04343	22,18005	-31,3285	2G
1,76E+18	0,196024	0,328283	0,048104	0,15439	0,031766	-0,07964	-0,02093	27,92487	22,15056	-31,4469	2G
1,76E+18	0,215906	-0,10831	0,048436	0,152175	0,036707	-0,01371	-0,05129	27,74362	22,04648	-31,5091	2G
1,76E+18	0,23579	0,106427	-0,04627	0,238476	0,027143	-0,10986	-0,06344	27,85258	22,10706	-31,4453	2G
1,76E+18	0,255672	0,347202	0,220915	0,104738	0,039397	-0,16808	-0,0679	27,7048	21,90201	-31,5818	2G
1,76E+18	0,275555	0,25773	0,274247	0,120157	0,079708	-0,22405	-0,03429	27,70924	22,24384	-31,813	2G
1,76E+18	0,295439	-0,14014	0,252748	0,337851	0,130821	-0,16481	0,00473	27,31483	22,02486	-31,9376	2G
1,76E+18	0,315321	-0,62985	0,149215	0,085772	0,195036	-0,02577	-0,0178	27,45586	22,01617	-32,1044	2G
1,76E+18	0,335204	-0,40577	0,250379	-0,23782	0,256474	0,078741	0,021728	27,40419	21,88949	-32,3975	2G
1,76E+18	0,355088	-0,48894	0,137383	-0,20871	0,28822	0,086742	0,041844	27,53038	21,63632	-32,5354	2G
1,76E+18	0,37497	-0,76912	-0,0335	-0,10634	0,290157	0,226441	0,053727	27,71779	21,41567	-32,4153	2G
1,76E+18	0,394854	0,281623	0,410631	-0,38873	0,322302	0,207953	0,120785	27,98616	21,15173	-32,2868	2G
1,76E+18	0,414736	0,272135	0,425539	0,005078	0,337334	-0,00548	0,087159	28,07895	20,93202	-32,4524	2G
1,76E+18	0,434619	0,432408	0,376767	-0,11526	0,350255	0,050959	0,122798	28,2238	20,62386	-32,4596	2G
1,76E+18	0,454503	-0,08078	-0,31592	0,289279	0,308804	-0,03048	0,112222	27,97853	20,38078	-32,5152	2G
1,76E+18	0,474385	0,441833	-0,20358	0,331035	0,297887	0,020803	0,152974	28,22925	20,05569	-32,4128	2G
1,76E+18	0,494269	0,236515	-0,17205	-0,0599	0,320578	0,012932	0,111326	27,90169	19,83541	-32,7996	2G
1,76E+18	0,514152	0,266948	-0,22659	-0,26489	0,302251	-0,01915	0,106949	27,90982	19,61906	-33,0527	2G
1,76E+18	0,534034	0,25108	-0,49126	-0,28173	0,224839	-0,07282	0,141678	28,12128	19,39374	-33,107	2G
1,76E+18	0,553917	0,706353	-0,45527	0,089503	0,135474	-0,3591	0,104149	27,96436	19,06207	-33,2034	2G
1,76E+18	0,573801	0,135991	-0,37464	-0,36153	0,185632	-0,06746	0,10553	27,78548	18,9249	-33,4334	2G
1,76E+18	0,593684	-0,42733	0,451338	0,309107	0,249155	0,042137	0,013881	27,71651	18,65269	-33,5532	2G
1,76E+18	0,613566	-0,05875	0,100938	-0,21658	0,239593	0,04846	0,030693	27,77501	18,46232	-33,8993	2G
1,76E+18	0,633449	0,002589	-0,10634	-0,16617	0,206708	0,044839	-0,01808	27,9649	18,29037	-33,8048	2G
1,76E+18	0,653333	0,302254	-0,17059	-0,05708	0,14782	-0,13792	0,007449	27,96736	18,21803	-33,921	2G
1,76E+18	0,673216	-0,0221	-0,44373	-0,32254	0,021625	-0,2272	-0,02381	27,77798	18,24098	-33,8762	2G
1,76E+18	0,693099	-0,73431	-0,72968	-1,1009	-0,14295	-0,31808	-0,05379	27,69264	18,13898	-33,8691	2G
1,76E+18	0,712982	-0,5314	-0,98259	-1,8867	-0,24778	-0,45058	0,14877	27,27184	18,21915	-33,9677	2G
1,76E+18	0,732864	-0,38692	-0,68701	-1,69861	-0,42412	-0,53786	0,288417	26,83176	18,36626	-34,2935	2G
1,76E+18	0,752748	-1,04169	-1,03776	-1,76902	-0,50809	-0,29463	0,364861	26,91321	18,52907	-34,2833	2G
1,76E+18	0,772631	-1,95522	-1,37658	-1,86385	-0,58347	0,205387	0,565873	26,82281	18,64434	-34,1171	2G
1,76E+18	0,792513	-1,76238	-1,41669	-1,39632	-0,57212	0,384457	0,475431	27,22905	18,74274	-33,7707	2G
1,76E+18	0,812397	-0,87719	-1,48945	-0,6769	-0,55583	-0,2463	0,567366	27,7943	18,80685	-33,6395	2G
1,76E+18	0,83228	0,002443	-2,37366	0,169224	-0,65379	-1,08401	0,452125	27,52602	18,91221	-33,6413	2G
1,76E+18	0,852162	-0,48733	-1,30334	0,279108	-0,5925	-0,85232	-0,00788	27,0076	19,37667	-33,6098	2G
1,76E+18	0,872046	-0,01911	1,798379	0,278521	-0,57265	-0,63549	0,251279	26,50523	19,81255	-33,7702	2G
1,76E+18	0,891928	-0,08653	2,842329	-0,55575	-0,35872	-0,67763	0,272188	25,9413	20,10228	-33,9336	2G
1,76E+18	0,911812	0,028722	1,084619	-0,66444	-0,46088	-0,54529	0,007766	25,65706	20,27052	-33,8629	2G
1,76E+18	0,931695	-0,62946	-0,39263	-0,92623	-0,67795	-0,79601	-0,15709	24,83153	20,62968	-34,417	2G
1,76E+18	0,951577	3,025441	0,900337	-0,47984	-0,60858	-1,45258	0,034176	24,17276	21,26642	-34,7068	2G
1,76E+18	0,971461	0,610694	0,5388	1,45628	-0,71897	-1,76353	0,030001	23,38608	21,31235	-34,9106	2G
1,76E+18	0,991344	-1,81586	0,735526	1,716603	-0,91535	-1,49345	-0,66702	21,9649	21,73766	-34,9083	2G
1,76E+18	1,011226	-2,64884	-0,14231	-0,80985	-1,0525	-0,51459	-0,65519	20,54404	22,74261	-35,148	2G
1,76E+18	1,03111	-0,88594	1,084272	1,203541	-0,825	-0,86117	-0,67309	19,58096	23,59548	-34,7562	2G
1,76E+18	1,050992	1,603401	1,818024	-0,86183	-0,76007	-1,24425	-0,18022	18,84404	24,608	-34,7755	2G
1,76E+18	1,070875	0,278137	-1,44508	1,885595	-0,76467	-1,34808	-0,33741	17,62894	25,13198	-34,4634	2G
1,76E+18	1,090759	-0,52144	-0,47199	-1,05799	-0,83851	-1,238	-0,48694	16,4084	25,96862	-34,4174	2G
1,76E+18	1,110641	1,56975	0,184825	-0,36327	-0,91512	-1,13524	-0,2184	15,15822	26,71416	-34,1554	2G
1,76E+18	1,130524	2,126972	-1,24843	1,123949	-0,87846	-0,75228	-0,12229	14,38144	27,38145	-34,0094	2G
1,76E+18	1,150407	-2,09479	-1,64377	-0,62651	-0,80093	-0,00838	-0,24597	13,65663	27,9557	-33,6308	2G
1,76E+18	1,170291	2,685314	-1,57327	-0,60165	-0,60582	-0,811	0,142371	13,51709	28,53577	-33,4545	2G
1,76E+18	1,190174	1,313089	-1,25414	1,64593	-0,64688	-0,67356	0,02293	12,85631	28,99429	-32,9989	2G
1,76E+18	1,210056	0,063611	-0,87243	1,161297	-0,69838	-0,06306	-0,1019	12,65025	29,56633	-32,9317	2G
1,76E+18	1,22994	0,532129	-0,08246	-0,24347	-0,67001	0,645043	0,025359	12,58807	30,14832	-32,4213	2G
1,76E+18	1,249823	1,823906	-0,27361	-0,79573	-0,66366	0,665192	0,314235	12,86044	30,50554	-31,8578	2G
1,76E+18	1,269706	1,721189	-0,08674	-0,14073	-0,8405	0,487589	0,409082	13,74036	30,99691	-31,2123	2G

1,76E+18	1,289589	3,033047	1,372126	0,844016	-0,81264	0,509906	0,198357	14,25888	31,38809	-30,7462	2G
1,76E+18	1,309472	1,962957	1,336731	0,534991	-0,72412	-1,23966	0,204998	14,40053	31,86623	-30,0358	2G
1,76E+18	1,329355	1,414399	-0,90134	2,077346	-0,55918	-1,91823	0,098444	13,77322	32,30102	-29,8921	2G
1,76E+18	1,349238	-0,97654	0,107595	1,288338	-0,28287	-1,37041	-0,26064	12,53236	32,69794	-29,8782	2G
1,76E+18	1,369121	0,395776	1,11401	-0,60515	-0,1057	0,847614	0,0339	12,19713	32,69889	-29,8133	2G
1,76E+18	1,389004	-4,34101	-2,94874	-2,58387	-0,35837	1,314235	-0,09225	12,92563	32,80388	-29,5993	2G
1,76E+18	1,408887	-1,83532	-1,4157	-0,89144	-0,4765	0,612741	-0,47214	13,50777	33,0462	-29,1753	2G
1,76E+18	1,42877	0,589006	-0,18996	1,819699	-0,64692	0,255187	-0,69391	13,27161	33,48731	-28,5517	2G
1,76E+18	1,448653	0,314282	0,011046	-0,8845	-0,21411	0,787137	-0,30828	13,22284	34,15396	-28,2007	2G
1,76E+18	1,468536	0,941677	0,137614	1,570179	-0,10963	0,050209	-0,06429	13,35548	34,24177	-27,8719	2G
1,76E+18	1,488419	0,245342	0,023172	0,058585	-0,06912	-0,14691	-0,18176	13,285	34,28845	-28,0079	2G
1,76E+18	1,508302	-1,33708	-0,9546	0,606816	-0,0083	-0,40484	-0,12955	13,11581	34,41344	-27,8498	2G
1,76E+18	1,528185	1,828855	1,238358	0,66654	0,178035	-0,64024	-0,10819	12,51494	34,48062	-27,8466	2G
1,76E+18	1,548068	3,437704	3,489905	-1,03648	-0,01753	-0,58936	0,018198	12,06218	34,24477	-28,0757	2G
1,76E+18	1,567951	3,714109	-0,46096	-0,24345	-0,30847	-0,51131	0,206548	11,69992	34,30607	-28,2036	2G
1,76E+18	1,587834	-1,91401	-2,73577	-0,53315	-0,50373	0,590152	-0,00912	11,65071	34,60897	-28,1645	2G
1,76E+18	1,607717	-7,13724	-2,22213	-1,3352	-0,09442	1,670904	-0,48433	11,98981	34,76244	-27,5773	2G
1,76E+18	1,6276	-2,25419	0,074276	0,514612	-0,18007	1,114577	-0,55801	12,45447	35,05211	-27,6377	2G
1,76E+18	1,647483	1,335603	1,805149	-1,13367	0,0612	0,545849	0,368981	12,81235	34,98754	-27,17	2G
1,76E+18	1,667366	0,261143	1,62622	-0,57447	0,284596	1,34241	0,572034	13,48795	34,73306	-27,1191	2G
1,76E+18	1,687249	-0,65784	-1,61509	2,203642	0,191836	1,25346	0,280714	14,80571	34,7264	-26,7482	2G
1,76E+18	1,707132	-0,1564	-0,80446	1,86088	0,283215	0,804023	0,344807	15,74959	34,51678	-26,8663	2G
1,76E+18	1,727015	0,952466	0,083892	-0,52978	0,397915	0,775825	0,538421	16,42966	34,30493	-26,7259	2G
1,76E+18	1,746898	-0,80627	-0,66358	-0,72704	0,370373	0,476033	0,211407	17,1913	33,98457	-27,0196	2G
1,76E+18	1,766781	0,457982	0,60491	0,063923	0,535994	0,588076	0,175695	17,63589	33,72601	-27,2301	2G
1,76E+18	1,786664	1,650007	0,34724	0,638676	0,577614	0,322193	0,347389	18,1411	33,35866	-27,5179	2G
1,76E+18	1,806547	-0,06352	-1,37647	-1,48472	0,459863	-0,2831	0,177254	18,47453	32,83132	-27,5954	2G
1,76E+18	1,82643	-1,10045	-1,88953	-0,07227	0,310412	-0,50181	0,144678	18,29028	32,52005	-28,3091	2G
1,76E+18	1,846313	0,354587	-1,73321	0,365274	0,325852	-0,09176	-0,59307	18,05441	32,47686	-28,6708	2G
1,76E+18	1,866196	0,094525	-0,41455	2,222188	0,345705	0,087927	-0,78138	17,42944	32,58772	-29,0884	2G
1,76E+18	1,886079	1,945668	-0,95331	2,649031	0,173	0,807432	-0,5705	17,06427	32,59699	-29,2969	2G
1,76E+18	1,905962	-0,27321	-0,95218	0,483221	0,388723	0,772515	-0,26639	17,18167	32,57167	-29,4048	2G
1,76E+18	1,925845	0,507006	-0,31729	0,512629	0,305083	0,775379	0,147856	17,57541	32,56802	-29,2748	2G
1,76E+18	1,945728	0,978686	-0,57218	-0,05196	0,085209	0,487796	0,217781	17,9837	32,57169	-29,3022	2G
1,76E+18	1,965611	0,510392	1,063358	1,106305	0,142778	0,478318	0,395761	18,59044	32,35091	-29,3276	2G
1,76E+18	1,985494	0,152243	2,379206	3,500359	0,163113	0,038641	0,289206	19,20151	32,37257	-29,4424	2G
1,76E+18	2,005377	0,07264	0,103464	1,272318	0,0974	-0,70568	0,170036	19,34163	32,21909	-29,5505	2G
1,76E+18	2,02526	0,368159	0,725438	0,135237	-0,08632	-0,54834	0,200878	19,16464	31,9058	-29,5539	2G
1,76E+18	2,045143	-0,58077	0,430115	-0,61265	-0,18679	-1,11561	0,041014	18,90953	31,94885	-29,715	2G
1,76E+18	2,065026	0,355827	-1,04267	0,308799	-0,20838	-1,39524	0,050741	17,9968	32,01461	-29,915	2G
1,76E+18	2,084909	-2,62649	0,755273	0,595596	-0,14028	-0,75921	0,011606	17,11337	32,26346	-30,0285	2G
1,76E+18	2,104792	-0,98214	-0,08262	-0,02627	-0,38763	-0,51629	0,290083	16,53294	32,29273	-30,2077	2G
1,76E+18	2,124675	1,559394	-1,25957	-0,82331	-0,30425	-1,82639	-0,00604	15,96725	32,52226	-30,0591	2G
1,76E+18	2,144558	-0,37714	1,179238	-0,58595	-0,10478	-1,8334	-0,84558	14,60114	32,77068	-30,5039	2G
1,76E+18	2,164441	-0,34583	0,011715	2,966143	0,055124	-2,18251	-1,02394	12,58534	33,11721	-30,9274	2G
1,76E+18	2,184323	0,076746	0,823686	2,540204	0,087691	-2,1178	-0,61881	10,3958	33,23319	-31,2563	2G
1,76E+18	2,204206	2,710071	1,161682	1,311937	0,325032	-1,90852	-0,48279	8,570175	33,31025	-31,7214	2G
1,76E+18	2,224088	-0,77278	1,57202	1,06166	0,483719	-1,64103	-0,33654	6,930588	33,20576	-31,8591	2G
1,76E+18	2,243971	0,415862	1,64442	1,03302	0,671157	-1,48816	-0,37663	5,310196	32,8567	-32,3725	2G
1,76E+18	2,263854	-0,36457	-2,33575	1,996108	0,681564	-1,25266	0,094105	3,987686	32,66327	-32,9744	2G
1,76E+18	2,283737	-3,16902	4,10433	-0,01385	1,037668	-0,89563	0,033024	3,234512	31,8289	-33,2793	2G
1,76E+18	2,30362	-1,20659	1,542608	2,66253	1,027978	-0,3244	0,105715	2,866272	31,22605	-33,9069	2G
1,76E+18	2,323503	-3,03987	1,302316	0,627587	0,916331	0,117689	0,122112	2,783127	30,48138	-34,5727	2G
1,76E+18	2,343386	-2,30052	-0,0395	1,530156	0,758707	-0,41641	0,012789	2,677612	29,98002	-34,7733	2G
1,76E+18	2,36327	1,997651	0,797553	0,564189	0,854382	-0,90487	0,107681	2,308487	29,3981	-35,4564	2G
1,76E+18	2,383152	0,123006	0,328236	-0,0693	0,971003	-1,62281	0,014885	1,463058	28,55253	-35,863	2G
1,76E+18	2,403035	-3,34337	0,14896	0,555775	1,234495	0,277593	-0,85967	0,393997	27,59286	-36,483	2G
1,76E+18	2,422918	-5,01276	-0,14291	2,990573	1,093609	-0,30478	-0,05978	0,159607	26,71697	-37,0323	2G
1,76E+18	2,442801	1,517899	3,412005	-0,31753	1,345049	0,389694	0,277231	0,574677	26,47371	-37,5408	2G
1,76E+18	2,462684	-0,42357	1,554589	2,486668	1,157327	0,199256	0,130024	0,818039	25,44184	-38,0095	2G
1,76E+18	2,482567	0,817456	1,980356	-0,82968	1,273568	0,018318	-0,24629	1,191025	24,38593	-38,62	2G
1,76E+18	2,50245	1,239681	-0,64935	1,004088	1,599736	0,150364	-1,00605	0,985901	23,35696	-39,3831	2G

1,76E+18	1,905962	-0,27321	-0,95218	0,483221	0,388723	0,772515	-0,26639	17,18167	32,57167	-29,4048	2G
1,76E+18	1,925845	0,507006	-0,31729	0,512629	0,305083	0,775379	0,147856	17,57541	32,56802	-29,2748	2G
1,76E+18	1,945728	0,978686	-0,57218	-0,05196	0,085209	0,487796	0,217781	17,9837	32,57169	-29,3022	2G
1,76E+18	1,965611	0,510392	1,063358	1,106305	0,142778	0,478318	0,395761	18,59044	32,35091	-29,3276	2G
1,76E+18	1,985494	0,152243	2,379206	3,500359	0,163113	0,038641	0,289206	19,20151	32,37257	-29,4424	2G
1,76E+18	2,005377	0,07264	0,103464	1,272318	0,0974	-0,70568	0,170036	19,34163	32,21909	-29,5505	2G
1,76E+18	2,02526	0,368159	0,725438	0,135237	-0,08632	-0,54834	0,200878	19,16464	31,9058	-29,5539	2G
1,76E+18	2,045143	-0,58077	0,430115	-0,61265	-0,18679	-1,11561	0,041014	18,90953	31,94885	-29,715	2G
1,76E+18	2,065026	0,355827	-1,04267	0,308799	-0,20838	-1,39524	0,050741	17,9968	32,01461	-29,915	2G
1,76E+18	2,084909	-2,62649	0,755273	0,595596	-0,14028	-0,75921	0,011606	17,11337	32,26346	-30,0285	2G
1,76E+18	2,104792	-0,98214	-0,08262	-0,02627	-0,38763	-0,51629	0,290083	16,53294	32,29273	-30,2077	2G
1,76E+18	2,124675	1,559394	-1,25957	-0,82331	-0,30425	-1,82639	-0,00604	15,96725	32,52226	-30,0591	2G
1,76E+18	2,144558	-0,37714	1,179238	-0,58595	-0,10478	-1,8334	-0,84558	14,60114	32,77068	-30,5039	2G
1,76E+18	2,164441	-0,34583	0,011715	2,966143	0,055124	-2,18251	-1,02394	12,58534	33,11721	-30,9274	2G
1,76E+18	2,184323	0,076746	0,823686	2,540204	0,087691	-2,1178	-0,61881	10,3958	33,23319	-31,2563	2G
1,76E+18	2,204206	2,710071	1,161682	1,311937	0,325032	-1,90852	-0,48279	8,570175	33,31025	-31,7214	2G
1,76E+18	2,224088	-0,77278	1,57202	1,06166	0,483719	-1,64103	-0,33654	6,930588	33,20576	-31,8591	2G
1,76E+18	2,243971	0,415862	1,64442	1,03302	0,671157	-1,48816	-0,37663	5,310196	32,8567	-32,3725	2G
1,76E+18	2,263854	-0,36457	-2,33575	1,996108	0,681564	-1,25266	0,094105	3,987686	32,66327	-32,9744	2G
1,76E+18	2,283737	-3,16902	4,10433	-0,01385	1,037668	-0,89563	0,033024	3,234512	31,8289	-33,2793	2G
1,76E+18											

1,76E+18	2,522333	3,766291	0,877795	5,316892	1,662445	-0,24484	-0,80787	0,548294	22,03944	-40,0828	2G
1,76E+18	2,542216	1,802305	1,520605	2,177773	1,582774	0,853682	-0,77643	0,273987	20,61197	-40,7018	2G
1,76E+18	2,562099	-3,50994	1,409483	-0,23297	1,487338	1,720947	-1,30335	0,602951	19,07128	-41,2701	2G
1,76E+18	2,581982	1,364781	0,372094	0,74962	1,290634	0,335423	-1,14485	1,449295	17,68307	-42,1283	2G
1,76E+18	2,601865	5,749341	-0,56259	-0,89482	1,050436	-0,80027	-1,05105	1,419739	16,61505	-42,5181	2G
1,76E+18	2,621748	0,352802	-0,14125	-2,01141	1,087942	-0,5681	-1,01748	0,416901	15,55244	-42,7097	2G
1,76E+18	2,641631	-3,6145	1,019464	0,542681	1,293646	0,398569	-1,01084	-0,3584	14,34397	-42,9543	2G
1,76E+18	2,661514	-1,62195	0,352112	2,516762	1,580783	0,507872	-0,92409	-0,12645	13,03139	-43,6131	2G
1,76E+18	2,681397	1,145649	1,145033	2,060726	1,70294	0,185361	-0,7348	0,129395	11,41647	-43,7715	2G
1,76E+18	2,70128	1,753111	-0,04923	1,078002	1,735153	-0,28092	-0,64752	0,16951	9,707932	-44,2018	2G
1,76E+18	2,721163	-0,25424	-0,00364	-0,54164	1,841952	-0,32752	-0,54958	0,052475	8,107391	-44,4709	2G
1,76E+18	2,741046	-1,56737	0,047837	-1,19624	1,967271	-0,0879	-0,56062	-0,13432	6,027283	-44,847	2G
1,76E+18	2,760929	-3,36557	-0,77343	-1,02416	2,203784	0,886547	-0,64241	0,054749	3,981918	-45,0627	2G
1,76E+18	2,780812	-4,50624	-1,74456	-0,08516	2,416301	1,49987	-1,06783	0,923523	1,636353	-45,1517	2G
1,76E+18	2,800695	-0,07204	-0,55517	1,272064	2,499818	1,754252	-1,63349	2,883728	-0,75079	-45,5434	2G
1,76E+18	2,820578	1,86142	2,532112	1,081546	2,490044	1,326979	-1,39282	4,595383	-3,14607	-45,5434	2G
1,76E+18	2,840461	1,700497	2,62546	1,774065	2,563902	0,201569	-0,87634	5,820023	-5,71001	-45,411	2G
1,76E+18	2,860344	0,635005	-0,20717	2,045495	2,441454	-0,42252	-1,06025	6,218811	-8,01903	-45,1844	2G
1,76E+18	2,880227	-0,50243	-1,14908	0,236719	2,398268	0,209792	-1,17574	6,38504	-10,3375	-44,8005	2G
1,76E+18	2,90011	-0,95639	0,231952	-0,35375	2,305785	0,846389	-1,15094	7,688049	-12,6873	-44,2844	2G
1,76E+18	2,919993	0,556706	1,900065	-1,11165	2,27665	1,096524	-0,9155	8,519897	-13,7947	-44,2869	2G
1,76E+18	2,939876	1,350822	0,691927	0,250786	2,20628	0,715687	-0,64777	9,939163	-15,8995	-43,3005	2G
1,76E+18	2,959759	0,727637	-1,54563	0,206099	2,093397	0,4634	-0,6313	11,35428	-17,9666	-42,9314	2G
1,76E+18	2,979642	-1,00178	-2,49906	0,465784	1,73419	0,823622	-0,72508	12,66905	-19,9508	-42,0212	2G
1,76E+18	2,999525	-1,51241	-1,64388	-0,65657	1,415786	1,24294	-0,93279	14,24841	-21,4746	-41,007	2G
1,76E+18	3,019408	-2,01369	-1,72537	-1,52783	1,134176	1,044975	-0,68315	16,13608	-22,8998	-40,1929	2G
1,76E+18	3,039291	1,666112	-0,10184	-0,77469	1,374968	0,632159	-0,29354	17,96588	-24,0288	-39,4109	2G
1,76E+18	3,059175	-0,08675	-0,96943	1,714795	1,368046	1,145327	-0,12643	19,18227	-25,3361	-38,3245	2G
1,76E+18	3,079057	-3,12839	-2,56458	0,85183	1,206927	1,41006	-0,34226	20,86226	-27,0065	-37,5872	2G
1,76E+18	3,09894	0,48193	-4,24669	0,464798	1,186522	1,094419	-0,39803	22,78563	-28,5261	-35,9889	2G
1,76E+18	3,118823	2,114436	-2,43026	1,312038	1,236065	0,597964	-0,43308	24,41158	-29,5676	-34,901	2G

1,76E+18	3,138706	1,421011	-1,04319	1,612425	1,348712	0,452708	-0,29453	25,62692	-30,8999	-33,8419	2G
1,76E+18	3,158589	0,922356	-0,60425	0,879679	1,346911	0,499253	-0,08987	26,59944	-32,2498	-32,7017	2G
1,76E+18	3,178472	-1,67676	-0,70149	0,748643	1,488817	0,784609	0,025811	27,81683	-33,7028	-31,3088	2G
1,76E+18	3,198355	-2,76383	-1,86154	2,640563	1,649358	1,276477	-0,87097	29,11861	-35,2494	-29,7356	2G
1,76E+18	3,218238	0,772707	0,2194	2,821566	1,629067	1,782544	-0,83696	31,1913	-36,4362	-27,344	2G
1,76E+18	3,238121	2,825914	-0,56239	2,882749	1,345957	2,188523	-0,71013	33,4691	-37,332	-24,7444	2G
1,76E+18	3,258005	2,583718	-0,5136	0,832841	1,093138	1,84707	-0,41556	35,54272	-38,0373	-21,6912	2G
1,76E+18	3,277887	0,962639	-0,32893	0,123329	1,070957	1,163398	-0,49663	37,37917	-38,7842	-18,9699	2G
1,76E+18	3,29777	1,812028	-0,25741	0,001868	1,139114	0,371176	-0,75344	38,71541	-39,1386	-16,6335	2G
1,76E+18	3,317654	2,516698	0,021998	1,424789	1,07078	0,338806	-0,75314	39,97955	-39,4753	-15,2114	2G
1,76E+18	3,337536	3,290702	-0,12615	0,816883	0,808909	0,376894	-0,60892	41,0862	-39,0504	-13,0968	2G
1,76E+18	3,357419	3,084333	0,631055	-0,29718	0,596087	0,119587	-0,36379	41,97263	-38,9878	-11,6624	2G
1,76E+18	3,377302	-0,98031	-0,54718	-2,26856	0,666218	0,526714	-0,36089	42,74751	-38,8403	-9,71402	2G
1,76E+18	3,397185	-2,19249	-0,39827	0,310168	0,68891	0,599069	-0,59314	43,23924	-38,5699	-8,72007	2G
1,76E+18	3,417068	3,045069	-0,6108	1,050628	0,706855	0,094864	-0,27641	44,36084	-38,5201	-6,62403	2G
1,76E+18	3,436951	3,037608	-0,67709	0,736358	0,729742	-0,50248	0,047109	44,81998	-38,0161	-5,17187	2G
1,76E+18	3,456834	3,162709	-0,0707	-0,45067	0,883037	-1,1426	0,375109	45,13438	-37,5825	-4,26041	2G
1,76E+18	3,476717	0,970448	-0,251	0,593618	0,801022	-0,86405	0,445382	44,67621	-37,8332	-2,25272	2G
1,76E+18	3,4966	-0,46591	-3,79473	2,506296	0,682978	-0,44897	0,076963	44,4722	-37,3631	-1,65164	2G
1,76E+18	3,516483	-0,74379	-2,58054	0,543182	0,605545	-0,3179	-0,20039	43,97572	-36,9234	-0,23471	2G
1,76E+18	3,536366	-1,97434	-1,66038	-1,71333	0,474716	0,317248	-0,48284	44,0764	-35,991	0,498486	2G
1,76E+18	3,55625	-6,26445	-0,50456	-1,28922	0,302205	2,105121	-0,82801	44,45277	-34,9957	1,821623	2G
1,76E+18	3,576132	-3,7274	2,429044	-0,45254	0,191295	2,867308	-0,93298	45,82188	-34,1718	4,712097	2G
1,76E+18	3,596015	2,92314	0,632773	0,61456	0,343401	2,437471	-0,81807	46,40086	-32,8782	8,261972	2G
1,76E+18	3,615898	6,207473	-0,80871	1,360018	0,661702	1,318537	-0,15675	46,26825	-31,5242	11,10804	2G
1,76E+18	3,635781	1,875303	-1,45408	1,526579	0,913899	0,302837	0,012636	46,1839	-30,508	13,06583	2G
1,76E+18	3,655665	0,874578	-1,20894	0,296227	0,997965	-0,20344	0,016323	46,02055	-29,7393	13,8743	2G
1,76E+18	3,675547	0,603632	-0,07247	-0,44195	1,012178	-0,07262	-0,06871	45,70961	-28,8393	15,04727	2G
1,76E+18	3,69543	-0,3527	-0,73613	0,381376	1,013373	0,470784	-0,21684	45,18465	-27,8637	15,60224	2G
1,76E+18	3,715313	2,165603	0,617067	1,873652	0,985673	0,341231	-0,16806	44,87126	-26,7924	17,1794	2G
1,76E+18	3,735197	3,053256	0,299591	-0,2947	0,977165	0,012227	-0,33069	44,58479	-25,5616	17,95499	2G

Lampiran 3. Sample Dataset Posisi Pengelasan 3G

time	onds_elap	accel_x	accel_y	accel_z	gyro_x	gyro_y	gyro_z	mag_x	mag_y	mag_z	label
1,76E+18	0,081755	-0,1686	-0,02981	-0,08352	0,010775	0,067014	-0,02287	35,3727	22,63318	-26,7074	3G
1,76E+18	0,101637	0,021954	-0,24179	0,02087	0,001536	0,009985	-0,0259	35,61957	22,70882	-26,5276	3G
1,76E+18	0,121519	0,196348	-0,09032	0,02731	0,004178	-0,01131	-0,0214	35,67934	22,74104	-26,596	3G
1,76E+18	0,141401	-0,00301	0,051086	0,024984	0,014091	-0,0089	-0,04656	35,62476	22,72962	-26,575	3G
1,76E+18	0,161283	-0,07196	-0,05475	0,0654	0,005426	-0,00031	-0,05251	35,61101	22,84566	-26,6747	3G
1,76E+18	0,181166	-0,105	-0,00046	0,024783	0,009484	0,035518	-0,03773	35,56158	22,84959	-26,7617	3G
1,76E+18	0,201048	-0,11619	0,009138	0,016274	0,012944	0,044157	-0,03702	35,69014	23,04414	-26,8194	3G
1,76E+18	0,22093	-0,07438	0,001454	0,003315	0,012153	0,044333	-0,03342	35,61703	22,81033	-26,7757	3G
1,76E+18	0,240812	0,003205	-0,00781	0,022269	0,008468	0,043709	-0,00714	35,55518	22,74375	-26,9648	3G
1,76E+18	0,260694	-0,00615	0,019625	0,20783	0,006264	0,044296	0,019624	35,63805	22,67034	-26,6425	3G
1,76E+18	0,280576	-0,17837	0,098847	0,25143	0,040534	0,082245	0,020942	35,81316	22,6328	-26,7995	3G
1,76E+18	0,300458	-0,20674	0,191305	0,206531	0,088329	0,064085	0,030544	35,89172	22,67544	-26,5641	3G
1,76E+18	0,32034	-0,04368	0,39522	0,142777	0,097321	-0,05608	0,060543	35,85056	22,49352	-26,7641	3G
1,76E+18	0,340222	-0,0041	0,636446	0,01287	0,10898	-0,19436	0,1109	35,75507	22,53748	-26,55	3G
1,76E+18	0,360104	-0,20723	0,863633	-0,23909	0,173823	-0,21532	0,141354	35,46954	22,28092	-26,988	3G
1,76E+18	0,379986	-0,36562	1,178235	0,142883	0,235141	-0,26947	0,128542	35,47014	22,02652	-27,1859	3G
1,76E+18	0,399868	-0,50285	0,86117	0,391169	0,334674	-0,3449	0,116142	35,4622	21,82809	-27,4368	3G
1,76E+18	0,41975	-0,49157	0,86655	0,484673	0,415969	-0,31885	0,134131	35,35623	21,58926	-27,7893	3G
1,76E+18	0,439632	-1,09842	1,072811	0,368111	0,489518	-0,17266	0,2541	35,29225	21,18698	-28,2301	3G
1,76E+18	0,459514	-1,3165	1,014177	-0,0041	0,619467	0,219088	0,38817	35,33804	20,73858	-28,449	3G
1,76E+18	0,479396	-0,5334	0,981093	-0,21051	0,724746	0,315179	0,487009	35,70851	20,03834	-28,5934	3G
1,76E+18	0,499278	0,165962	0,56251	-0,08825	0,778534	0,105735	0,575488	35,61766	19,59489	-28,5087	3G
1,76E+18	0,51916	-0,09484	0,620412	0,03408	0,818419	-0,05859	0,514961	35,93575	18,78956	-28,665	3G
1,76E+18	0,539042	0,144596	1,001855	0,36444	0,826571	-0,42769	0,445349	36,11972	17,96053	-29,2382	3G
1,76E+18	0,558924	0,8351	1,01253	0,39829	0,782229	-0,75534	0,446231	35,97539	17,12089	-29,9955	3G
1,76E+18	0,578806	0,300065	0,766284	0,139026	0,756064	-0,70395	0,475647	35,53584	16,30178	-30,4408	3G
1,76E+18	0,598688	-1,03797	0,184728	-0,18713	0,784146	-0,43205	0,452518	35,37059	15,65658	-31,0761	3G
1,76E+18	0,61857	-1,09438	0,003653	-0,50486	0,903622	-0,07039	0,495421	35,25887	14,83179	-31,6438	3G
1,76E+18	0,638452	-0,31328	0,482149	-0,5276	1,04359	0,054843	0,621374	35,24013	13,79326	-31,9048	3G
1,76E+18	0,658334	-0,36207	-0,0916	-0,14628	1,062827	0,01028	0,599448	35,47717	12,911	-32,2248	3G
1,76E+18	0,678216	-0,44348	0,158215	-0,75856	1,256189	0,234136	0,623897	35,6796	11,78809	-32,491	3G
1,76E+18	0,698098	-0,14686	-0,3622	-1,09857	1,226583	0,23925	1,057931	35,80208	10,55173	-32,3635	3G
1,76E+18	0,71798	-2,72298	-1,32071	0,978214	0,71321	-0,01617	1,438384	36,14944	9,115395	-32,6694	3G
1,76E+18	0,737862	-3,46134	-0,83486	0,405919	0,627858	0,352773	1,310569	36,50787	7,660843	-32,7264	3G
1,76E+18	0,757744	-1,00332	0,218882	0,316487	0,544837	0,581679	1,266533	36,94386	5,952637	-32,7118	3G
1,76E+18	0,777626	-1,08578	0,239126	0,560524	0,531711	0,117498	1,109286	37,36792	4,926331	-32,5375	3G
1,76E+18	0,797508	-2,22998	-0,19899	0,619541	0,679019	0,508584	0,913278	37,51872	3,772018	-32,0406	3G
1,76E+18	0,81739	-2,93014	-0,45404	1,081515	0,663352	0,771686	0,578199	38,04974	2,848663	-31,6489	3G
1,76E+18	0,837272	-1,20008	-0,80209	2,068212	0,51929	0,538233	0,465313	38,26387	2,044617	-31,2676	3G
1,76E+18	0,857154	0,977246	-1,21967	1,534296	0,505172	0,53937	0,659685	38,68193	1,427002	-30,7219	3G
1,76E+18	0,877036	0,414368	-0,686	1,235259	0,609287	0,293942	0,831552	38,80167	0,460587	-30,4728	3G
1,76E+18	0,896918	0,173688	-0,5894	0,787916	0,665286	0,085696	0,895862	38,89342	-0,71899	-30,3621	3G
1,76E+18	0,9168	-0,7347	-0,74615	-0,19519	0,693699	-0,05856	0,809099	38,98228	-1,77409	-30,2553	3G
1,76E+18	0,936682	-0,8377	-0,55737	-0,00528	0,684222	-0,06299	0,70696	38,86726	-2,78868	-30,2637	3G
1,76E+18	0,956566	-0,93948	-0,49711	0,187518	0,70886	-0,16637	0,756655	38,76758	-3,73828	-30,3324	3G
1,76E+18	0,976446	-0,3771	0,123353	-0,00039	0,824874	-0,47333	0,786484	38,57768	-4,2688	-30,5122	3G
1,76E+18	0,996328	-0,0765	0,370841	-0,46499	1,0253	-0,29921	1,042218	38,38547	-5,41049	-30,9413	3G
1,76E+18	1,01621	-2,22196	0,275758	-0,29695	1,048101	0,638159	1,021142	37,8997	-6,78346	-30,7234	3G
1,76E+18	1,036092	-3,62488	-0,63564	0,559274	0,903969	1,000606	0,782216	38,11084	-8,22743	-30,3946	3G
1,76E+18	1,055974	-0,68084	-1,5618	1,237026	0,683712	0,907501	0,542556	38,34352	-9,36017	-29,4203	3G
1,76E+18	1,075856	0,048314	-0,73214	1,458422	0,626254	0,836108	0,322134	38,67447	-10,2277	-28,5153	3G
1,76E+18	1,095738	0,469866	-0,36612	2,133162	0,581756	0,926256	0,297961	39,19289	-10,9065	-27,7422	3G
1,76E+18	1,11562	1,031677	-0,33202	1,658402	0,53556	1,118478	0,462827	39,87581	-11,3788	-26,8903	3G
1,76E+18	1,135502	1,471083	0,100651	0,620746	0,438829	1,040452	0,559762	40,34534	-12,164	-25,8773	3G
1,76E+18	1,155384	2,296515	-0,15557	1,240272	0,35181	0,195828	0,45867	40,53278	-12,9276	-25,085	3G
1,76E+18	1,175266	1,79616	-0,8308	1,427654	0,469082	-0,18476	0,406437	40,36885	-13,5713	-24,7903	3G
1,76E+18	1,195147	-1,01589	-1,72301	2,898484	0,558974	-0,44943	0,121925	40,08723	-14,1395	-24,7294	3G
1,76E+18	1,21503	-1,51699	-1,61256	2,059689	0,699738	-0,26146	0,009387	40,18884	-14,5932	-24,983	3G
1,76E+18	1,234911	-0,68269	-1,26098	1,130068	0,697893	0,003312	0,06188	40,04138	-14,891	-25,2585	3G
1,76E+18	1,254793	0,816304	-0,05531	-0,30242	0,693069	0,182053	0,149135	40,09245	-15,4368	-24,6991	3G
1,76E+18	1,274676	1,747091	1,02554	-0,40301	0,571905	-0,2125	0,204953	39,90002	-15,8678	-24,3583	3G
1,76E+18	1,294558	2,986118	0,184145	-0,04409	0,32832	-0,61459	0,291614	39,71298	-16,3216	-24,2723	3G
1,76E+18	1,314439	2,291931	-1,42334	0,277966	0,068284	-0,72268	0,234142	39,35223	-16,642	-24,6026	3G

1,76E+18	1,334321	1,085504	-1,46311	-0,73428	0,065552	-0,10541	0,24242	38,84801	-17,1043	-25,0913	3G
1,76E+18	1,354203	-0,36466	-0,5281	-0,34096	0,075626	0,458602	0,072841	38,95892	-17,1314	-24,8781	3G
1,76E+18	1,374085	-0,28129	-0,43876	0,334223	0,103469	0,984138	-0,12375	39,25099	-17,3613	-24,3705	3G
1,76E+18	1,393968	0,011676	-0,9842	1,186532	0,097007	2,092674	-0,36825	40,06541	-17,2161	-23,1647	3G
1,76E+18	1,41385	-2,48841	-0,81575	-0,66854	0,284297	3,979097	-1,15539	41,39636	-16,7177	-20,9387	3G
1,76E+18	1,433731	-3,44727	2,123505	-0,44993	0,660749	4,362611	-1,55129	43,6506	-15,7692	-17,1913	3G
1,76E+18	1,453614	2,585598	0,593289	0,69985	0,569628	1,935832	-0,53992	44,61375	-15,0841	-15,1309	3G
1,76E+18	1,473496	5,739401	0,434455	2,081596	0,346097	0,19948	0,124986	45,44798	-14,5721	-13,1004	3G
1,76E+18	1,493377	1,939487	-0,83743	1,621201	0,176047	0,188299	0,263895	45,32552	-14,778	-12,343	3G
1,76E+18	1,51326	-2,85247	-0,72747	0,5785	0,070906	0,931228	0,134247	45,44637	-15,1406	-12,2298	3G
1,76E+18	1,533141	-2,95388	-0,42412	-0,11162	0,115138	1,198205	0,018868	45,64299	-15,2932	-11,4814	3G
1,76E+18	1,553023	-0,53687	0,282915	-1,03544	0,294905	1,410313	-0,01026	45,83171	-15,4884	-9,89963	3G
1,76E+18	1,572906	0,392819	0,725877	-1,24687	0,373527	1,236301	-0,04885	45,93973	-15,4709	-8,65091	3G
1,76E+18	1,592787	0,741097	1,030135	-1,1038	0,17623	1,000408	0,001343	46,06999	-15,576	-7,40903	3G
1,76E+18	1,612669	-0,85436	1,075508	-0,9695	0,359777	2,062968	0,039539	46,27713	-15,33	-6,57896	3G
1,76E+18	1,63255	-2,26087	0,949678	-1,31481	0,637886	2,80412	0,146375	46,3732	-15,4637	-4,47216	3G
1,76E+18	1,652432	-0,46934	0,356323	-1,17391	0,572187	2,571841	0,395166	46,41963	-15,7067	-1,66397	3G
1,76E+18	1,672314	1,345151	-0,5348	-1,12119	0,508395	1,778407	0,445735	46,3324	-16,2243	0,890368	3G
1,76E+18	1,692197	2,094219	-1,04911	-0,84216	0,531655	0,997816	0,375835	45,95509	-16,5786	2,608114	3G
1,76E+18	1,712079	2,539756	-0,56199	-1,83102	0,603259	0,264112	0,429219	45,54457	-16,9868	3,848675	3G
1,76E+18	1,73196	1,615103	0,550666	-2,43343	0,902551	0,528568	0,861412	45,6058	-17,4342	4,536551	3G
1,76E+18	1,751843	-0,89064	1,015198	-2,84812	1,297389	0,777518	0,983968	45,21324	-18,224	5,492656	3G
1,76E+18	1,771724	-3,23966	1,533737	-0,36686	0,66422	-0,67571	0,901343	44,59981	-18,9904	6,10166	3G
1,76E+18	1,791606	-1,72471	-1,61668	4,012699	-0,13519	-0,88107	0,894797	44,38142	-19,8634	5,75828	3G
1,76E+18	1,811489	-0,47346	-0,56023	2,253771	-0,21656	-1,99649	0,622353	44,10638	-20,6479	4,60501	3G
1,76E+18	1,83137	0,732159	0,747892	1,017406	-0,0373	-3,25214	0,320339	44,28075	-21,0736	2,496298	3G
1,76E+18	1,851252	4,67043	2,415182	2,410552	0,229948	-4,1307	1,041746	43,8924	-21,5532	-0,54996	3G
1,76E+18	1,871135	3,805543	1,451305	1,861923	0,545753	-4,09619	1,366462	43,20708	-22,5673	-3,9571	3G
1,76E+18	1,891016	0,809586	0,326404	1,710817	0,788411	-4,05582	1,033639	42,14052	-23,6272	-7,09139	3G
1,76E+18	1,910898	-2,66403	-0,8106	-0,26844	0,968962	-3,22506	0,329816	41,38725	-24,3713	-9,65205	3G
1,76E+18	1,93078	-2,35159	0,539703	-1,90956	1,05328	-1,63389	0,056781	40,68831	-24,7064	-11,247	3G
1,76E+18	1,950663	-2,06182	0,637078	-2,02203	0,916238	0,306592	-0,10931	40,77441	-24,647	-11,6111	3G
1,76E+18	1,970545	-5,68023	1,209416	-4,44311	0,725804	3,054946	-0,82993	41,0063	-24,6725	-10,5911	3G
1,76E+18	1,990427	-7,19769	1,22386	-2,61097	0,565146	5,278502	-1,38998	41,77739	-24,1967	-7,58045	3G
1,76E+18	2,010309	-7,4069	1,441524	-0,43193	0,892231	5,737473	-1,57114	43,0007	-23,1412	-2,76766	3G
1,76E+18	2,03019	5,316338	6,003751	3,182794	0,513046	2,108751	0,848629	43,35191	-22,1446	2,202908	3G
1,76E+18	2,050072	3,521632	-0,34949	-0,25125	0,540662	2,420105	1,842942	42,59027	-23,0095	5,011082	3G
1,76E+18	2,069955	-4,99338	-2,43298	-2,8908	0,613089	3,046603	0,643116	41,46927	-24,232	7,521605	3G
1,76E+18	2,089836	-2,37844	-0,4318	-0,62799	0,30499	3,450703	0,216331	40,38223	-24,9634	10,70619	3G
1,76E+18	2,109719	2,654724	0,409625	-1,11429	0,159192	2,970643	-0,11627	39,16856	-25,1788	13,47659	3G
1,76E+18	2,1296	3,823126	0,41132	-0,69276	0,419359	3,145622	-0,29056	38,16124	-25,2299	15,99014	3G
1,76E+18	2,149482	1,522293	-0,0222	1,047084	0,581243	2,295845	0,147856	36,94456	-25,2041	19,03819	3G
1,76E+18	2,169365	0,507911	-3,29526	5,333188	-0,04308	1,030842	0,365011	35,85217	-25,5394	20,90265	3G
1,76E+18	2,189247	0,105961	1,049077	3,616439	-0,19932	-0,69556	0,383208	35,0955	-25,8804	21,49625	3G
1,76E+18	2,209129	2,468961	1,951865	1,78861	-0,12934	-1,91455	0,626619	35,09813	-26,4339	21,15251	3G
1,76E+18	2,229011	3,682678	0,931105	1,532312	0,147819	-2,7962	1,003048	35,55994	-26,9919	19,76937	3G
1,76E+18	2,248893	1,718641	0,698044	1,681304	0,299137	-3,69316	1,383734	35,98279	-27,7733	17,61588	3G
1,76E+18	2,268775	1,368435	-1,73878	0,988028	0,156423	-3,57695	1,599545	36,24049	-28,721	15,71549	3G
1,76E+18	2,288657	0,064359	-1,20383	0,152078	0,079668	-3,30137	1,057041	36,38962	-29,6766	13,38457	3G
1,76E+18	2,308539	0,844165	-0,27393	-1,24035	0,082876	-2,4155	0,848901	36,41258	-30,2645	11,55621	3G
1,76E+18	2,328421	-0,04939	0,630783	0,681388	0,404903	-2,35031	0,623811	36,42476	-30,9049	10,06875	3G
1,76E+18	2,348303	0,604843	2,178426	2,107237	0,470599	-2,99112	0,794777	36,51096	-31,1415	8,970589	3G
1,76E+18	2,368185	-1,73891	2,361043	-1,60718	0,516698	-1,67613	0,6822	36,47928	-31,496	7,576791	3G
1,76E+18	2,388067	-3,02709	1,451112	-4,21583	0,273683	0,549387	-0,20744	36,22542	-31,6836	7,82018	3G
1,76E+18	2,407949	-4,80362	2,740944	-0,97758	0,115381	2,005142	-0,91779	36,18127	-31,1885	9,196136	3G
1,76E+18	2,427831	-1,5482	1,377151	0,239419	0,142335	1,729239	-0,74351	36,43686	-30,7548	10,36868	3G
1,76E+18	2,447713	2,238232	-2,6655	-4,523	-0,08743	1,539728	-0,16957	36,18382	-30,3749	12,22052	3G
1,76E+18	2,467595	-5,13042	1,066893	-3,41796	0,350666	3,421315	0,469266	35,59813	-30,2251	14,05897	3G
1,76E+18	2,487477	-5,36868	3,395966	0,11049	0,896534	4,817632	1,272719	33,98544	-30,5856	17,25729	3G
1,76E+18	2,507359	0,480618	-1,57713	2,603199	0,640083	3,751823	0,39724	30,85788	-30,9883	21,65701	3G
1,76E+18	2,527241	4,833451	-3,05551	1,425841	0,18923	1,57938	0,274482	28,34888	-31,1785	25,02417	3G
1,76E+18	2,547123	3,338916	1,523159	-1,54366	0,198041	0,666501	0,655673	26,57043	-31,2793	26,84946	3G
1,76E+18	2,567005	-0,06217	2,477791	-2,32211	0,823546	1,325518	0,453919	25,23827	-31,3972	28,34211	3G
1,76E+18	2,586887	1,584565	1,631037	0,416141	1,001889	2,022671	0,872496	23,28033	-31,0979	30,45252	3G

1,76E+18	2,606769	-0,33359	0,316935	9,704898	0,021908	-0,31124	0,619246	20,99559	-31,1507	32,66465	3G
1,76E+18	2,626651	1,405304	5,557129	1,137292	0,374693	-0,47403	0,867633	20,13831	-30,9205	33,45154	3G
1,76E+18	2,646533	0,946292	-0,67941	-0,24486	0,979146	-1,16138	1,039846	19,27194	-30,5461	34,41041	3G
1,76E+18	2,666415	-0,05177	-4,3356	2,239994	0,680509	-3,38193	0,852487	19,17778	-29,8364	35,08667	3G
1,76E+18	2,686297	-0,08519	-1,76035	1,015611	0,523891	-3,68687	0,784335	20,44283	-29,2598	34,93323	3G
1,76E+18	2,706179	-3,09421	-0,52891	-1,34577	0,657597	-2,55037	0,877523	21,823	-28,6254	34,00362	3G
1,76E+18	2,726061	-4,22915	-1,70562	-1,30646	0,816591	-1,77328	0,578111	22,45241	-27,7176	34,09755	3G
1,76E+18	2,745943	-1,33632	-0,00532	-0,80684	0,845845	-1,63823	0,652596	22,90872	-26,7589	34,20494	3G
1,76E+18	2,765825	-1,62878	1,442858	-2,38438	1,021647	-0,84595	0,571264	22,98091	-25,6243	34,31563	3G
1,76E+18	2,785706	-0,83003	0,980008	-0,70966	1,032672	-0,5582	0,423224	22,68239	-24,1714	35,0078	3G
1,76E+18	2,805588	0,689863	1,114572	0,24499	1,072365	-0,33499	0,62459	22,23196	-22,5239	35,9222	3G
1,76E+18	2,82547	0,466512	0,615337	1,013995	1,046058	-0,64113	0,880899	21,54521	-21,0052	36,90112	3G
1,76E+18	2,845352	-1,38456	-0,13002	0,869758	1,093874	-0,60883	0,893233	20,95834	-19,5305	37,26933	3G
1,76E+18	2,865234	-2,03375	-0,45883	0,05356	1,149734	-0,11934	0,900474	20,48453	-18,6257	38,0598	3G
1,76E+18	2,885116	-1,1511	-0,62416	2,193079	1,165672	0,178678	0,910402	19,65135	-16,9758	38,37066	3G
1,76E+18	2,904998	-1,31475	-0,70002	4,270866	1,234854	0,289504	0,554906	19,07968	-16,6922	39,12805	3G
1,76E+18	2,92488	0,204604	-0,67998	0,888254	1,258051	0,736065	0,412587	18,21255	-14,9108	39,02583	3G
1,76E+18	2,944762	-0,80295	-0,97316	0,388462	1,333365	1,047098	0,204795	17,25612	-12,8259	39,37356	3G
1,76E+18	2,964644	-0,46102	-0,75497	0,829169	1,430954	0,688116	0,016148	16,14197	-11,1783	39,5684	3G
1,76E+18	2,984526	-0,25296	-1,29983	1,228513	1,523635	0,716569	-0,02668	15,47536	-8,65038	39,96947	3G
1,76E+18	3,004408	-1,22105	-1,31611	1,139465	1,484861	0,989419	-0,13005	14,90724	-6,93069	39,49679	3G
1,76E+18	3,02429	-2,03774	-0,97779	0,137044	1,501651	1,35822	-0,30432	13,74591	-4,27409	39,23136	3G
1,76E+18	3,044172	-1,07098	-0,28927	1,492172	1,542671	1,07166	-0,50562	12,66278	-2,46082	39,10012	3G
1,76E+18	3,064054	1,648951	0,47533	2,060903	1,348348	0,615984	-0,43373	11,87286	-0,68359	37,94278	3G
1,76E+18	3,083936	-0,25953	0,868022	1,035849	1,465944	1,006384	-0,32239	11,46326	0,567093	37,43633	3G
1,76E+18	3,103818	1,49027	-0,28051	2,607056	1,514193	0,880625	0,171526	11,08788	2,357986	36,58274	3G
1,76E+18	3,1237	2,039883	-1,61159	2,288304	1,459418	-0,06823	0,413522	10,71718	3,505112	35,69114	3G
1,76E+18	3,143582	1,500327	0,435196	1,985421	1,314499	-0,65398	0,275494	11,33246	4,296387	34,78801	3G
1,76E+18	3,163464	1,463538	0,483872	1,204969	0,944285	-1,51569	0,415803	12,39375	5,830612	33,63417	3G
1,76E+18	3,183336	-1,40513	-1,91264	-0,55658	0,863908	-1,4551	0,062295	13,4948	5,746262	32,27744	3G
1,76E+18	3,203227	0,351352	-1,39441	0,373803	1,015953	-1,42117	0,030431	14,80011	6,643875	31,15131	3G
1,76E+18	3,223109	1,26457	-1,6466	-0,02692	1,010018	-1,89021	0,254354	16,11333	6,960648	29,83244	3G
1,76E+18	3,242991	0,88244	-1,02987	-1,18944	0,971012	-2,10053	0,495184	17,52211	7,430191	28,68095	3G
1,76E+18	3,262873	0,166489	-0,80405	-1,58749	0,968409	-2,84613	0,551656	19,00177	7,482407	27,26179	3G
1,76E+18	3,282755	1,099276	-0,29517	-1,60373	1,000163	-3,7269	0,636246	20,91299	7,571136	25,34857	3G
1,76E+18	3,302637	-0,43669	-0,64939	-0,06799	0,906093	-3,97355	0,549035	22,79906	7,332504	22,84009	3G
1,76E+18	3,32252	-2,46377	-0,99789	-2,33822	0,824811	-3,31052	0,320586	24,56108	7,177231	20,46213	3G
1,76E+18	3,342401	-1,42225	-1,68302	-2,49008	0,810268	-2,50567	0,0719	25,5545	7,186966	18,55502	3G
1,76E+18	3,362283	-0,57546	-0,67961	-1,17653	0,888742	-2,22435	0,010675	26,27986	7,224503	16,86149	3G
1,76E+18	3,382166	-1,31172	0,841396	-0,29162	0,964468	-1,41503	-0,0935	26,7025	7,149277	15,48122	3G
1,76E+18	3,402047	-0,77132	0,097243	-1,16968	0,960838	-0,95744	-0,225	26,56474	7,202026	15,27063	3G
1,76E+18	3,421929	-0,5268	0,03664	-1,49448	1,005073	-0,36638	-0,18669	26,6752	7,578018	14,00945	3G
1,76E+18	3,441811	-0,6089	0,914478	-1,18713	1,077897	0,117441	-0,1855	26,57278	7,813553	13,29836	3G
1,76E+18	3,461693	-0,06364	0,581911	-0,83572	1,137765	0,358568	-0,28899	26,18169	8,177521	12,99156	3G
1,76E+18	3,481575	-0,23351	0,43459	-0,23877	1,142485	0,106722	-0,40576	25,94025	8,567383	12,47662	3G
1,76E+18	3,501457	0,133255	-0,05429	-0,63894	1,121881	0,004341	-0,48113	25,52502	9,074005	12,06591	3G
1,76E+18	3,521339	0,560503	-0,20182	-0,45827	1,11567	0,066027	-0,55029	25,2605	9,477295	11,40194	3G
1,76E+18	3,541221	0,527747	-1,35859	0,223453	1,0442	0,464392	-0,67859	25,04254	9,751678	11,11698	3G
1,76E+18	3,561104	-0,60294	-3,66158	0,820939	0,972838	1,019203	-0,85465	24,64992	10,12009	11,15629	3G
1,76E+18	3,580986	-0,6707	-3,80271	0,237096	0,923207	1,345329	-0,9942	24,08327	10,79247	11,36208	3G
1,76E+18	3,600867	0,298436	-1,30034	-0,77847	0,932161	1,343783	-0,93822	23,32382	11,37196	11,65623	3G
1,76E+18	3,62075	0,21883	-0,34276	-0,8065	0,914434	1,427963	-0,99408	22,85629	11,87611	12,26551	3G
1,76E+18	3,640632	0,207835	-0,7056	-0,68582	0,838333	1,74402	-1,08835	22,19461	12,38348	12,62023	3G
1,76E+18	3,660513	1,193172	-0,64043	-1,2943	0,735285	1,793164	-0,95215	21,37282	13,05263	12,92064	3G
1,76E+18	3,680395	1,729895	-0,35541	-0,23138	0,601308	1,4181	-0,66238	20,67857	13,78821	13,33502	3G
1,76E+18	3,700277	1,673551	-0,76812	0,422768	0,527624	1,189093	-0,47628	20,01302	14,01038	13,6008	3G
1,76E+18	3,720159	0,586313	-1,70879	0,44665	0,488603	1,172504	-0,50947	19,54337	14,37831	14,17599	3G
1,76E+18	3,740042	0,055497	-1,13991	-0,57354	0,458903	1,075331	-0,55098	18,99442	14,65587	14,41994	3G
1,76E+18	3,759923	0,708867	-1,23974	0,072851	0,480047	0,477241	-0,57537	18,43057	15,16702	14,65627	3G
1,76E+18	3,779805	1,450977	-0,13883	0,60721	0,494407	-0,00138	-0,44128	18,0905	15,5535	14,26615	3G
1,76E+18	3,799687	0,93469	0,000906	1,103144	0,482774	-0,20777	-0,2417	17,82347	15,88686	14,03636	3G
1,76E+18	3,81957	0,440053	-0,14476	1,250692	0,37909	-0,06966	-0,14949	17,57338	15,99046	13,79456	3G
1,76E+18	3,839452	-0,40506	0,270094	0,26533	0,335886	0,180648	-0,26622	17,36609	16,46492	13,69937	3G
1,76E+18	3,859333	0,494874	0,686834	0,285493	0,35919	0,521447	-0,28722	17,00682	16,54316	13,70966	3G

Lampiran 4. *Sample Dataset* Posisi Pengelasan 4G

time	onds_elap	accel_x	accel_y	accel_z	gyro_x	gyro_y	gyro_z	mag_x	mag_y	mag_z	label
1,76E+18	0,078304	0,4582	-0,05486	-0,29159	0,237287	0,351705	0,223425	43,34207	-13,341	-16,6634	4G
1,76E+18	0,098188	0,447065	0,037942	-0,4266	0,212224	0,161565	0,134115	43,09323	-13,7543	-16,4717	4G
1,76E+18	0,118072	0,480402	-0,10051	-0,39972	0,194808	-0,10688	0,082006	43,09874	-13,9344	-16,339	4G
1,76E+18	0,137956	0,426869	-0,14961	-0,33421	0,185827	-0,28003	0,093764	43,2305	-13,984	-16,1838	4G
1,76E+18	0,157839	0,24045	0,19581	-0,07624	0,200678	-0,27233	0,15186	43,07214	-14,0355	-16,3699	4G
1,76E+18	0,177723	-0,32391	0,202743	0,047916	0,264243	0,00457	0,222551	42,92256	-14,308	-16,5689	4G
1,76E+18	0,197607	-0,52195	0,503321	0,104179	0,357103	0,301818	0,232138	43,04826	-14,6362	-16,3416	4G
1,76E+18	0,217491	-0,15961	0,596785	0,234916	0,452571	0,506373	0,229221	43,14951	-14,8848	-15,9899	4G
1,76E+18	0,237374	-0,18664	0,338868	0,272467	0,52266	0,579525	0,167469	43,21335	-15,3713	-15,3848	4G
1,76E+18	0,257258	-0,02967	-0,03554	0,280134	0,54697	0,516581	0,082591	43,36548	-15,5688	-14,7527	4G
1,76E+18	0,277142	-0,02069	-0,08146	0,283554	0,525893	0,411507	0,01336	43,36749	-15,9494	-13,8905	4G
1,76E+18	0,297026	-0,44807	0,359844	0,239023	0,510686	0,279858	-0,05635	43,49252	-15,9795	-13,4819	4G
1,76E+18	0,31691	-0,85397	0,2947	0,329052	0,483827	0,194196	-0,14508	43,50298	-16,0202	-13,1281	4G
1,76E+18	0,336793	-1,75519	0,115452	-0,168	0,447049	0,230972	-0,22287	43,67157	-15,9581	-12,8906	4G
1,76E+18	0,356677	-1,71942	-0,35337	-0,23834	0,373751	0,322094	-0,22859	43,68343	-15,8987	-12,7945	4G
1,76E+18	0,376561	-0,94961	-0,21984	-0,05134	0,295777	0,287046	-0,23085	43,84123	-15,6903	-12,1463	4G
1,76E+18	0,396445	-0,31735	-0,01171	0,145278	0,227567	0,268109	-0,2934	43,98918	-15,6675	-11,9606	4G
1,76E+18	0,416328	-0,72485	-0,0209	0,06639	0,193042	0,455405	-0,40363	44,34755	-15,2936	-11,3398	4G
1,76E+18	0,436212	-0,87046	-0,28891	0,023128	0,134967	0,561216	-0,53745	44,56871	-14,8978	-10,9975	4G
1,76E+18	0,456096	-0,23606	-0,9548	0,281527	0,004424	0,427295	-0,57396	44,74408	-14,5658	-10,5881	4G
1,76E+18	0,47598	-0,44345	-0,38785	-0,05484	-0,05559	0,375708	-0,66172	44,85663	-13,9893	-10,0294	4G
1,76E+18	0,495863	-0,21271	0,029301	-0,03193	-0,04667	0,306664	-0,73077	45,24355	-13,2056	-9,74788	4G
1,76E+18	0,515747	0,042402	0,671705	-0,01089	-0,02643	0,254312	-0,8067	45,3969	-12,4939	-9,49044	4G
1,76E+18	0,535631	-0,5471	0,452486	0,198211	-0,08584	0,24764	-0,82981	45,57423	-11,8352	-9,17213	4G
1,76E+18	0,555515	-1,04246	-0,21997	0,307346	-0,16291	0,345043	-0,83868	45,72485	-11,0011	-8,85648	4G
1,76E+18	0,575398	-1,19329	-0,28138	0,431892	-0,19195	0,394973	-0,86237	46,02689	-10,0907	-8,70192	4G
1,76E+18	0,595282	-1,17457	-0,11426	0,487161	-0,23105	0,438642	-0,94597	46,15347	-9,72514	-8,72064	4G
1,76E+18	0,615166	-1,08136	0,036294	0,605631	-0,25288	0,419416	-1,1562	46,36728	-8,81345	-8,39336	4G
1,76E+18	0,63505	-0,57269	0,243483	0,700114	-0,28006	0,301521	-1,40325	46,54854	-7,73608	-8,03088	4G
1,76E+18	0,654934	-0,3149	0,507673	0,611299	-0,27347	0,176667	-1,56919	46,79558	-6,46365	-8,0973	4G
1,76E+18	0,674817	-0,27846	0,693366	1,08669	-0,24143	0,054192	-1,61206	46,96844	-4,8374	-7,71828	4G
1,76E+18	0,694701	-0,26453	0,40901	1,360368	-0,17861	0,014508	-1,64442	47,18121	-3,32814	-7,72081	4G
1,76E+18	0,714585	-0,35698	0,106374	1,785719	-0,09875	-0,01854	-1,74977	47,16345	-1,58833	-7,90833	4G
1,76E+18	0,734469	-0,43309	-0,49872	2,079791	-0,01452	-0,03214	-1,8782	47,1937	0,162064	-7,75695	4G
1,76E+18	0,754352	-0,57994	-0,94009	2,203607	0,074075	-0,06107	-1,95452	47,1794	1,883438	-7,95695	4G
1,76E+18	0,774236	-0,49529	-1,06988	2,328093	0,140716	-0,12798	-1,91224	46,95479	3,812332	-7,97425	4G
1,76E+18	0,79412	-0,40747	-0,90719	2,131156	0,179978	-0,1222	-1,77463	46,94666	5,668289	-8,26382	4G
1,76E+18	0,814004	-0,48949	-0,88631	2,14346	0,224641	-0,16015	-1,62424	46,55066	7,290092	-8,41797	4G
1,76E+18	0,833887	-0,1894	-1,16526	2,302818	0,257789	-0,25698	-1,53605	46,21237	8,662697	-8,38905	4G
1,76E+18	0,853771	0,203219	-1,1202	2,37426	0,291548	-0,41544	-1,43202	45,96324	9,97287	-8,97672	4G
1,76E+18	0,873655	-0,09708	-0,545	1,789631	0,38996	-0,44639	-1,26805	45,51985	11,22085	-9,55411	4G
1,76E+18	0,893539	-0,2614	-0,25473	1,196166	0,554749	-0,34273	-1,12528	45,27673	12,26943	-10,0255	4G
1,76E+18	0,913422	-0,22263	0,227895	1,01436	0,739406	-0,22056	-0,9692	44,93312	13,10876	-10,4642	4G
1,76E+18	0,933306	0,033829	0,325542	0,749668	0,874355	-0,20148	-0,80863	44,66306	13,77971	-11,0019	4G
1,76E+18	0,95319	-0,25786	-0,11391	0,625658	0,942195	-0,19194	-0,68295	44,5455	14,40571	-11,0085	4G
1,76E+18	0,973074	-0,24673	-0,17436	0,30989	1,020478	-0,19847	-0,58825	44,13116	14,60082	-11,5905	4G
1,76E+18	0,992958	-0,3718	0,418377	-0,00301	1,113416	-0,21496	-0,49284	43,85016	14,71481	-12,2509	4G
1,76E+18	1,012841	-0,62664	0,775344	-0,1792	1,199479	-0,2327	-0,38334	43,5898	14,85173	-12,9052	4G
1,76E+18	1,032725	-0,93247	0,50219	0,062232	1,267111	-0,2234	-0,34069	43,74437	14,72624	-13,317	4G
1,76E+18	1,052609	-1,39654	-0,04646	-0,00464	1,372038	-0,18976	-0,38259	43,52545	14,63499	-13,8549	4G
1,76E+18	1,072493	-1,37494	-0,18515	-0,42481	1,398049	-0,29074	-0,38563	43,30307	14,41332	-14,3312	4G
1,76E+18	1,092376	-1,4155	0,741709	-1,41479	1,382636	-0,33105	-0,31303	43,11983	14,23995	-15,0467	4G
1,76E+18	1,11226	-1,52126	1,847477	-1,41915	1,380383	-0,28508	-0,25566	42,82678	13,90896	-15,7068	4G
1,76E+18	1,132144	-1,99456	2,194396	-1,17341	1,376663	-0,12652	-0,2598	42,60324	13,8279	-16,41	4G
1,76E+18	1,152028	-2,37783	1,815346	-1,49244	1,379141	0,037793	-0,29121	42,66701	13,62571	-16,7163	4G
1,76E+18	1,171911	-2,15273	1,192262	-1,86568	1,40282	0,134646	-0,2172	42,69945	13,40832	-17,3283	4G
1,76E+18	1,191795	-2,17848	1,578461	-2,12792	1,449823	0,210126	-0,07458	42,63437	13,12647	-17,5011	4G
1,76E+18	1,211679	-1,58242	1,70534	-1,86713	1,50499	0,253256	0,050663	42,62138	12,70922	-17,9198	4G
1,76E+18	1,231563	-2,39675	1,595567	-1,69598	1,547255	0,493719	0,04395	42,73215	12,02754	-17,8157	4G
1,76E+18	1,251446	-2,78938	0,488508	-2,0401	1,517714	0,729393	0,046199	42,89825	11,4051	-17,5955	4G
1,76E+18	1,27133	-3,0608	-0,13757	-2,21293	1,430704	0,916336	0,162306	43,25305	10,82706	-17,2083	4G
1,76E+18	1,291214	-2,63132	0,864911	-2,23	1,331628	1,049674	0,31341	43,85651	10,146	-16,8805	4G
1,76E+18	1,311098	-2,05121	1,61506	-1,93043	1,236693	1,05199	0,473108	44,24615	9,461395	-16,1653	4G

1,76E+18	1,330981	-1,73552	1,448531	-1,80569	1,131705	0,99165	0,586426	44,68517	8,668266	-15,3394	4G
1,76E+18	1,350865	-1,61075	0,455575	-1,74174	0,959527	0,92475	0,660335	44,83768	7,67469	-14,7699	4G
1,76E+18	1,370749	-1,3836	0,515997	-1,7733	0,793558	0,804101	0,69037	45,22401	6,585785	-13,937	4G
1,76E+18	1,390633	-0,77397	0,421339	-1,53334	0,616807	0,730282	0,630146	45,73888	5,857193	-13,5583	4G
1,76E+18	1,410516	-0,6767	0,000324	-1,48815	0,475262	0,659703	0,582114	45,84897	5,053345	-12,6986	4G
1,76E+18	1,4304	-0,2723	-1,03368	-1,16955	0,339959	0,443639	0,500203	46,14102	4,383698	-12,3888	4G
1,76E+18	1,450284	-0,08197	-1,83469	-1,05447	0,23345	0,18527	0,412496	46,1795	3,87384	-12,0947	4G
1,76E+18	1,470168	-0,35765	-1,89531	-1,26997	0,184999	0,095021	0,250269	46,27014	3,548309	-11,9225	4G
1,76E+18	1,490051	-0,48707	-1,95942	-1,21667	0,220098	0,130848	0,051539	46,24661	3,332825	-11,7754	4G
1,76E+18	1,509935	-0,02489	-1,52421	-1,41022	0,328868	0,372415	-0,00712	46,33092	3,261032	-11,6236	4G
1,76E+18	1,529819	-0,17355	-1,78397	-1,29488	0,356187	0,671949	0,069797	46,46465	3,128922	-11,3215	4G
1,76E+18	1,549703	0,336577	-2,0768	-1,00496	0,279656	0,723231	0,262622	46,50902	2,88681	-11,0186	4G
1,76E+18	1,569587	1,232301	-1,92142	-0,55526	0,155211	0,554996	0,354314	46,68088	2,501877	-10,2564	4G
1,76E+18	1,58947	1,927284	-1,16142	-0,23077	0,066638	0,338965	0,310815	46,83945	2,148224	-9,7448	4G
1,76E+18	1,609354	2,124077	-0,81985	-0,08426	-0,02361	0,139805	0,226166	47,13075	1,999252	-9,72049	4G
1,76E+18	1,629238	1,349907	-1,46519	-0,22064	-0,1263	0,060782	0,16389	47,18491	1,675964	-9,33808	4G
1,76E+18	1,649122	0,746835	-2,26887	-0,05667	-0,19838	0,222019	0,180139	47,22523	1,559189	-9,21993	4G
1,76E+18	1,669005	0,809596	-2,76144	0,219382	-0,21739	0,427186	0,223603	47,45561	1,41391	-8,79532	4G
1,76E+18	1,688889	1,461458	-3,30152	0,449584	-0,25609	0,49412	0,271502	47,49382	1,265686	-8,34403	4G
1,76E+18	1,708773	1,691928	-3,2274	0,260462	-0,29272	0,38341	0,329688	47,61386	1,098953	-7,88402	4G
1,76E+18	1,728657	1,762069	-2,33025	0,158231	-0,32143	0,125698	0,422202	47,73894	0,850281	-7,47688	4G
1,76E+18	1,74854	1,756488	-1,23104	0,055639	-0,35906	-0,06742	0,541548	47,68126	0,303391	-7,49574	4G
1,76E+18	1,768424	1,506802	-0,1945	0,031133	-0,37547	-0,13733	0,631748	47,59802	-0,27731	-7,39662	4G
1,76E+18	1,788308	0,813905	0,27786	-0,00865	-0,34769	-0,13099	0,718063	47,80794	-0,72682	-7,39528	4G
1,76E+18	1,808192	0,193714	0,061675	-0,07502	-0,30155	-0,26752	0,966597	48,07484	-1,61557	-8,03361	4G
1,76E+18	1,828075	0,213944	-0,42662	0,249888	-0,33519	-0,49951	1,368926	47,98758	-2,44823	-8,44292	4G
1,76E+18	1,847959	-0,4174	0,154275	0,947617	-0,40046	-0,37849	1,4852	47,77667	-3,75414	-8,56616	4G
1,76E+18	1,867843	-1,22794	0,550118	0,744183	-0,4318	0,001265	1,50092	47,51361	-5,38869	-8,52655	4G
1,76E+18	1,887727	-0,62632	0,729146	0,657353	-0,45856	0,083926	1,581045	47,46471	-6,83513	-8,71309	4G
1,76E+18	1,90761	-0,8749	0,746299	0,668647	-0,52999	0,111477	1,605181	47,0822	-8,22115	-8,83388	4G
1,76E+18	1,927495	-1,3424	0,965289	0,090934	-0,6096	0,242705	1,707474	47,14729	-9,76991	-8,47406	4G
1,76E+18	1,947379	-1,53571	1,147285	-0,0115	-0,70385	0,581581	1,795604	46,88489	-11,4357	-8,25833	4G
1,76E+18	1,967263	-1,67465	1,007543	0,682971	-0,88195	0,750761	2,014051	46,85675	-13,1118	-7,68021	4G
1,76E+18	1,987146	-2,66943	-0,4015	0,301939	-1,08619	0,94139	2,319876	46,57501	-15,0239	-6,88892	4G
1,76E+18	2,00703	-2,32207	-1,30762	0,87393	-1,41196	0,883685	2,785704	45,81776	-17,3898	-6,62687	4G
1,76E+18	2,026914	-2,62153	-1,49307	0,519196	-1,59529	0,837852	3,180631	44,9702	-20,2753	-6,35055	4G
1,76E+18	2,046798	-1,13831	-0,43739	0,571431	-1,69898	0,810321	3,405926	44,25197	-21,8213	-6,12352	4G
1,76E+18	2,066681	-0,27209	0,772335	0,487032	-1,71159	0,428825	3,385311	42,92404	-24,6106	-6,20709	4G
1,76E+18	2,086565	1,012317	0,914248	-0,31485	-1,62274	-0,89359	3,470097	41,28087	-27,6576	-6,35335	4G
1,76E+18	2,106449	-0,27616	1,557751	0,726818	-1,45485	-1,84902	3,496306	39,25275	-30,5135	-7,73176	4G
1,76E+18	2,126333	-3,01204	0,872978	0,902955	-1,07106	-1,87134	3,613062	36,4727	-33,4818	-9,78232	4G
1,76E+18	2,146216	-3,06477	1,492358	0,010267	-0,55332	-1,29472	3,630337	33,63557	-35,9189	-11,4749	4G
1,76E+18	2,1661	-2,11001	2,001916	-0,09315	-0,1064	-0,79625	3,607157	30,35457	-38,7389	-12,3795	4G
1,76E+18	2,185984	-1,69026	2,748857	-0,79692	0,303466	-0,32302	3,692442	27,16728	-41,4467	-12,5251	4G
1,76E+18	2,205868	-2,78143	1,701912	-1,20531	0,564833	-0,02026	4,200372	23,83566	-44,1074	-11,8208	4G
1,76E+18	2,225751	-3,19727	0,847829	-1,90726	0,607878	0,471188	4,458998	19,50208	-46,8	-10,9753	4G
1,76E+18	2,245635	-1,69663	-0,55772	-1,82426	0,363053	0,721575	4,559201	15,02136	-49,2433	-9,58557	4G
1,76E+18	2,265519	-0,37956	-1,50406	-0,58687	0,156054	0,599599	4,616896	10,15703	-51,1006	-8,23812	4G
1,76E+18	2,285403	-0,89512	-2,35012	-0,01344	0,0483	0,821787	4,436629	4,849335	-52,6033	-7,48449	4G
1,76E+18	2,305287	-0,98177	-3,39848	0,620144	0,099082	0,631538	4,133057	-0,63693	-53,1811	-6,27198	4G
1,76E+18	2,32517	-1,71059	-3,15439	0,313325	0,290875	0,30751	3,909184	-5,96774	-53,3097	-5,30457	4G
1,76E+18	2,345054	-2,29658	-2,59704	-1,26925	0,365924	0,027627	3,892855	-11,1595	-52,8058	-4,30884	4G
1,76E+18	2,364938	-2,49405	-1,75288	-2,57942	0,25297	0,209687	3,743438	-16,2896	-51,6178	-2,75302	4G
1,76E+18	2,384822	-3,26683	-1,65692	-1,56063	0,232701	0,358197	3,461943	-21,0537	-49,9479	-1,65812	4G
1,76E+18	2,404705	-1,31463	-0,94331	0,162481	0,327529	-0,04415	3,20854	-25,408	-47,7903	-0,50307	4G
1,76E+18	2,424589	-0,84739	-0,50785	0,433069	0,426572	-0,46026	3,053616	-29,0757	-45,3288	1,273127	4G
1,76E+18	2,444473	-1,76634	-2,68605	0,291247	0,452318	-0,24835	2,849726	-32,4208	-42,4692	3,052536	4G
1,76E+18	2,464357	-0,7391	-3,98681	0,839269	0,345646	-0,19871	2,50993	-35,3284	-39,7681	4,622896	4G
1,76E+18	2,48424	0,815223	-3,80681	1,873896	0,466098	-0,69661	2,254248	-37,3137	-36,9086	6,183262	4G
1,76E+18	2,504124	0,254645	-5,2723	2,662099	0,629154	-1,11391	2,013198	-38,7778	-33,8404	8,402219	4G
1,76E+18	2,524008	-0,73838	-6,92516	3,123363	0,676973	-1,01659	1,799273	-39,1104	-32,6322	9,496363	4G
1,76E+18	2,543892	0,04919	-7,52015	2,67324	0,507663	-1,06407	1,632375	-39,7439	-29,7587	11,09484	4G
1,76E+18	2,563775	0,015253	-7,37922	1,535124	0,307519	-0,87985	1,460328	-40,1384	-27,5621	13,2588	4G
1,76E+18	2,583659	0,807437	-6,01493	1,374538	0,319541	-0,95258	1,246446	-40,0663	-25,4052	14,9264	4G

1,76E+18	2,603543	1,197048	-5,94432	2,046978	0,216156	-0,80269	0,745162	-39,7836	-23,5717	16,27307	4G
1,76E+18	2,623427	2,592566	-5,70986	0,901704	0,276154	-1,15853	0,574248	-39,5261	-22,2699	17,49541	4G
1,76E+18	2,643311	-1,37253	0,415268	0,636491	0,477964	-0,79729	0,654278	-38,7677	-20,9265	18,7581	4G
1,76E+18	2,663194	1,467201	1,148466	-2,44373	0,452768	-0,82901	0,626578	-38,2762	-19,7274	20,0012	4G
1,76E+18	2,683078	1,229987	0,44276	-3,87419	0,22944	-0,69788	0,448838	-37,7312	-18,676	21,27236	4G
1,76E+18	2,702962	0,049564	1,091484	-1,83531	0,270914	-0,53863	0,180788	-37,1489	-17,5925	22,26655	4G
1,76E+18	2,722846	-0,91105	-0,00866	-1,08778	0,280391	-0,28786	0,007191	-36,3955	-16,664	23,19512	4G
1,76E+18	2,742729	-1,27404	-0,63421	-1,45874	0,175511	-0,33312	0,031092	-35,7846	-16,031	23,82047	4G
1,76E+18	2,762613	-0,94088	-1,44616	-2,10602	0,048827	-0,41127	0,091514	-35,0195	-15,2399	24,65247	4G
1,76E+18	2,782497	-1,05023	-0,94398	-2,4192	-0,10979	-0,07085	0,024126	-34,4871	-14,5457	25,40984	4G
1,76E+18	2,802381	-0,67775	0,050528	-1,3677	-0,12588	0,026421	0,013422	-34,2139	-13,7898	26,00916	4G
1,76E+18	2,822264	-0,88639	-0,45153	-0,76136	-0,12833	0,174228	0,062059	-33,9671	-13,0618	26,7645	4G
1,76E+18	2,842148	-0,72977	0,78652	0,418097	0,08148	0,317487	0,168224	-33,3717	-12,3987	26,9938	4G
1,76E+18	2,862032	0,301949	-0,31433	-0,14553	0,135789	0,536409	0,152934	-33,4973	-11,5411	27,15331	4G
1,76E+18	2,881916	0,104715	-0,09443	-0,68467	0,227141	0,647225	0,195141	-33,3444	-10,408	27,36368	4G
1,76E+18	2,9018	0,529274	0,302214	-0,21396	0,178943	0,453976	0,20743	-33,2142	-9,58102	27,56344	4G
1,76E+18	2,921681	0,811148	0,112123	0,779634	0,294858	-0,148	0,412268	-32,0986	-7,99748	27,49196	4G
1,76E+18	2,941566	0,39634	-0,01168	-0,03047	0,279918	-0,3542	0,466195	-31,2902	-6,59544	28,20981	4G
1,76E+18	2,961449	0,369726	-0,30059	-0,24251	0,209107	-0,22537	0,434101	-30,5083	-5,30919	28,96115	4G
1,76E+18	2,981333	0,644338	-0,42232	0,49795	0,169466	-0,18502	0,371139	-29,772	-4,26726	29,23895	4G
1,76E+18	3,001217	0,807187	-0,11056	0,734047	0,156002	-0,45411	0,329401	-31,6662	-0,02737	33,65354	4G
1,76E+18	3,021101	0,314436	-0,22402	0,460204	0,342895	-0,77632	0,388165	-30,315	0,88736	34,43172	4G
1,76E+18	3,040985	0,425444	-0,74916	-0,00085	0,423155	-0,89573	0,330126	-28,9297	1,99678	34,96599	4G
1,76E+18	3,060869	0,195872	-1,21235	-0,23713	0,448551	-0,85645	0,211573	-28,6822	4,9729	40,59628	4G
1,76E+18	3,080752	0,032978	-1,47844	-0,42796	0,35757	-0,9121	0,019348	-27,173	6,119263	40,90425	4G
1,76E+18	3,100635	-0,43757	-0,58126	-0,8847	0,325098	-0,91637	-0,07926	-25,6047	7,178772	43,99851	4G
1,76E+18	3,120519	-1,12519	-0,11005	-0,75707	0,289558	-0,79733	-0,12469	-24,0625	8,067612	44,77774	4G
1,76E+18	3,140404	-1,13324	-0,21797	-0,28707	0,342787	-0,70053	-0,0977	-22,5607	8,131729	47,13662	4G
1,76E+18	3,160287	-0,45391	-0,3527	-0,22814	0,402926	-0,68877	-0,02111	-21,0439	9,094315	47,62223	4G
1,76E+18	3,180171	-0,27462	0,00735	-0,23951	0,428005	-0,64064	0,00383	-19,611	10,11356	48,06131	4G
1,76E+18	3,200054	-0,19238	0,138517	-0,02687	0,445389	-0,71793	-0,00218	-18,0947	11,06953	47,83374	4G
1,76E+18	3,219938	-0,51434	0,114007	0,090741	0,466363	-0,78974	-0,00461	-16,5433	11,52202	52,26453	4G
1,76E+18	3,239823	-0,83504	0,064634	-0,24861	0,414056	-0,69018	-0,01798	-15,1153	12,37957	52,08683	4G
1,76E+18	3,259707	-1,0578	0,123841	0,027554	0,360457	-0,62341	-0,07644	-13,4389	13,31229	53,32626	4G
1,76E+18	3,27959	-0,92818	-0,06104	0,421968	0,311323	-0,70427	-0,09536	-12,2064	14,11816	53,13305	4G
1,76E+18	3,299474	-1,13604	-0,03344	0,266633	0,274487	-0,65002	-0,09162	-11,0574	14,75196	52,72853	4G
1,76E+18	3,319357	-1,24633	-0,08526	0,064461	0,243299	-0,49827	-0,0918	-9,04187	15,70913	55,12621	4G
1,76E+18	3,339241	-1,46736	-0,09138	0,15596	0,2421	-0,40034	-0,06959	-7,9581	16,35201	54,82284	4G
1,76E+18	3,359125	-1,24193	-0,02506	0,285777	0,273593	-0,40465	-0,02414	-7,233	17,07789	54,60616	4G
1,76E+18	3,379009	-1,41783	-0,00727	0,330975	0,287302	-0,34588	-0,0379	-6,25734	17,48431	54,09785	4G
1,76E+18	3,398893	-1,57974	-0,16718	0,662122	0,29874	-0,27744	-0,03566	-4,58305	18,46965	56,46693	4G
1,76E+18	3,418777	-1,75742	-0,57094	1,063365	0,287211	-0,25691	-0,0108	-3,82144	19,09429	55,80074	4G
1,76E+18	3,438659	-1,73891	-0,75372	1,136219	0,254772	-0,28501	-0,01195	-3,24963	19,56149	55,83249	4G
1,76E+18	3,458543	-1,87132	-0,89539	0,833206	0,190792	-0,1874	-0,01488	-2,84271	19,96431	55,71896	4G
1,76E+18	3,478427	-1,18953	-0,84774	0,888269	0,177594	-0,19122	-0,06784	-2,55641	20,23833	55,58025	4G
1,76E+18	3,498312	-0,68163	-0,73605	1,14835	0,218768	-0,27152	-0,06702	-1,42798	21,32774	57,03556	4G
1,76E+18	3,518195	-0,55352	-0,39355	0,997607	0,243195	-0,29625	0,006721	-1,06133	21,49731	57,07032	4G
1,76E+18	3,538079	-0,78094	0,198201	0,406936	0,220635	-0,19436	0,096243	-0,6113	22,03544	57,11826	4G
1,76E+18	3,557962	-1,00109	0,728968	0,085742	0,135115	-0,08696	0,180095	-0,15073	22,32868	56,9473	4G
1,76E+18	3,577846	-1,25455	0,73043	0,319706	0,037249	-0,05122	0,261266	0,364502	22,82799	56,55269	4G
1,76E+18	3,59773	-1,25022	0,365957	0,581408	-0,05296	-0,01792	0,286419	0,59491	23,02747	56,58934	4G
1,76E+18	3,617614	-0,63558	0,169869	0,455407	-0,08332	0,041971	0,261354	1,022461	23,04247	56,27161	4G
1,76E+18	3,637498	-0,60601	-0,31737	0,333431	-0,10292	0,148116	0,233042	0,913315	23,16431	56,0411	4G
1,76E+18	3,657382	-0,59041	-0,73609	0,363998	-0,14185	0,17563	0,17475	1,090378	23,2424	55,85714	4G
1,76E+18	3,677265	-0,90467	-1,15492	0,313471	-0,21389	0,172988	0,086575	1,279816	23,3867	55,65551	4G
1,76E+18	3,69715	-1,1984	-0,77661	0,021046	-0,26615	0,149612	0,028083	1,472992	23,52341	55,8466	4G
1,76E+18	3,717032	-1,3058	-0,02923	-0,12428	-0,21641	0,106852	0,074466	1,434601	23,57731	55,83287	4G
1,76E+18	3,736917	-1,32803	-0,00993	-0,33732	-0,15491	0,231717	0,1457	1,400726	23,75171	55,69402	4G
1,76E+18	3,756801	-0,98223	-0,40744	-0,60665	-0,14572	0,407012	0,1769	1,317047	23,71362	55,91109	4G
1,76E+18	3,776685	-0,13772	-1,09519	-0,18621	-0,12964	0,399196	0,145571	-0,98849	27,61051	54,73122	4G
1,76E+18	3,796567	0,325062	-1,18201	0,294081	-0,06624	0,252038	0,099592	-1,11665	27,97281	55,08579	4G
1,76E+18	3,816451	0,342283	-0,52681	0,336166	0,054203	0,169374	0,070666	-1,14726	28,2406	55,35614	4G
1,76E+18	3,836335	-0,00987	-0,2858	0,34494	0,100189	0,248042	0,021644	-0,76984	28,52987	55,37582	4G
1,76E+18	3,856219	0,030342	-0,23091	0,74907	0,097788	0,258139	0,007948	-0,73726	28,94981	55,30684	4G

Lampiran 5. Biodata Mahasiswa

1. Nama : Chika Bintang Yudina Rahmania
2. NRP : 0922040055
3. Program Studi : D4 – Teknik Otomasi
4. Agama : Islam
5. Status : Belum Menikah
6. Alamat Asal : Gunung Anyar Tengah II no.5 Surabaya
7. Nomor Telepon : 089616619716
8. Jenis Kelamin : Perempuan
9. Email : chikarahmaaa6@gmail.com
10. Tempat, Tanggal Lahir : Surabaya, 21 Januari 2004
11. Nama Orang Tua/Wali : Wahidin
12. Alamat Orang Tua/Wali : Gunung Anyar Tengah II No.5 Surabaya
13. Telepon Orang Tua/Wali : 08123537876
14. Riwayat Pendidikan :



Pendidikan Formal			
Pendidikan	Tahun	Tempat Pendidikan	Jurusan
Diploma 4	2022 - 2026	Politeknik Perkapalan Negeri Surabaya	Teknik Otomasi
SMA	2019 – 2022	SMAN 20 Surabaya	MIPA
SMP	2018 – 2019	SMPN 35 Surabaya	-
SD	2010 – 2016	SDN Rungkut Kidul II Surabaya	-

(Halaman ini sengaja dikosongkan)