

Rancang Bangun Sarung Tangan Pengenalan Bahasa Isyarat Kondisi Tubuh Berbasis Sistem Sensor dan Pembelajaran Mesin

1st Fadhil Azhar Alfarisi
Direktorat Kampus Purwokerto
Universitas Telkom Purwokerto
Brebes, Indonesia

azharalf@student.telkomuniversity.ac.id

2nd Aldo Rohan Hiskia Saragih
Direktorat Kampus Purwokerto
Universitas Telkom Purwokerto
Medan, Indonesia

aldorohan@student.telkomuniversity.ac.id

3rd Muhammad Makhdhori
Direktorat Kampus Purwokerto
Universitas Telkom Purwokerto
Jakarta, Indonesia

makhdhori@student.telkomuniversity.ac.id

4th Sevia Indah Purnama, S.ST., M.T
Direktorat Kampus Purwokerto
Universitas Telkom Purwokerto
Purwokerto, Indonesia

alyafandi@telkomuniversity.ac.id

5th Mas Aly Afandi, S.ST., M.T
Direktorat Kampus Purwokerto
Universitas Telkom Purwokerto
Purwokerto, Indonesia

seviaindah@telkomuniversity.ac.id

Abstrak---Penyandang disabilitas tunarungu atau tunawicara sering mengalami kesulitan dalam menyampaikan kondisi tubuh melalui bahasa isyarat kepada orang normal, sehingga menimbulkan hambatan komunikasi dan interaksi sosial. Untuk mengatasi masalah ini, dikembangkan sebuah sistem sarung tangan berbasis sensor dan *machine learning* yang mampu mengenali dan menerjemahkan bahasa isyarat terkait kondisi tubuh. Sistem ini menggunakan *flex sensor* untuk mendeteksi lekukan jari, mikrokontroler ESP32 beserta *expansion board* sebagai unit pemroses serta LCD 16x2 dengan modul IIC sebagai tampilan *output*. Data sensor diklasifikasikan ke dalam 8 kondisi tubuh seperti batuk, flu, diare, sakit leher, sakit lengan, sakit kaki, sakit kepala, dan pusing dan dapat ditampilkan secara *real-time* dengan waktu respon rerata 0.10 detik dalam bentuk teks. Desain sarung tangan dipilih untuk meningkatkan kenyamanan dan probabilitas. Hasil pengujian menunjukkan bahwa sistem mampu mengenali 8 kondisi tubuh dengan akurasi 86% dan waktu respons yang cepat.

Kata kunci : Bahasa Isyarat, *Flex Sensor*, MPU6050, *Machine Learning*, Sarung Tangan

I. PENDAHULUAN

Bahasa isyarat merupakan peranan utama sebagai sarana komunikasi utama bagi para tunarungu dan tunawicara. Namun, tantangan sering muncul karena kurangnya pemahaman bahasa isyarat di kalangan masyarakat umum. Menyadari kesenjangan komunikasi ini terutama pada pelayanan kesehatan, berbagai inovasi teknologi terus bermunculan dalam upaya menjembatani kesenjangan tersebut [1]. Kondisi ini mengakibatkan sejumlah dampak negatif bagi penyandang disabilitas, termasuk potensi keterlambatan dalam mendapatkan penanganan medis yang tepat waktu, kesulitan dalam menyampaikan keluhan kesehatan secara akurat [2]. Penelitian terdahulu telah berupaya mengembangkan sarung tangan pintar dengan

sensor dan mikrokontroler untuk mengenali bahasa isyarat berupa huruf dan angka. Akan tetapi, sebagian besar penelitian ini masih memiliki keterbatasan, terutama dalam hal fokus utama penelitian tersebut baru sebatas pada pengenalan alfabet dan angka, sementara aspek penting lain seperti isyarat yang berkaitan dengan kondisi tubuh belum banyak dieksplorasi. Keterbatasan-keterbatasan ini mengindikasikan adanya ruang untuk inovasi lebih lanjut dalam mengembangkan sarung tangan pintar yang lebih akurat dan komprehensif [3]. Teknologi sarung tangan pintar yang inovatif memanfaatkan bahasa isyarat untuk mengidentifikasi kondisi tubuh secara *real-time*. Memanfaatkan kombinasi sensor lekukan jari dan posisi tangan, solusi ini melacak pergerakan tangan secara keseluruhan dalam ruang tiga dimensi. Selanjutnya algoritma pembelajaran mesin yang telah dilatih secara khusus digunakan untuk menganalisis data yang ditangkap oleh sensor-sensor ini. Algoritma ini bekerja untuk menemukan pola gerakan isyarat yang menunjukkan masalah tubuh yang berbeda. Solusi yang diusulkan dalam penelitian ini menawarkan sejumlah keunggulan dibandingkan dengan penelitian-penelitian sebelumnya. Pertama, fokus utama sistem ini adalah pada penerjemahan bahasa isyarat yang berkaitan dengan kondisi tubuh. Dengan begitu dapat dibuatnya teknologi pengenalan bahasa isyarat dengan deteksi gerakan selain alfabet dan angka [4][5].

II. KAJIAN TEORI

A. Bahasa Isyarat

Bahasa isyarat merupakan alat komunikasi sehari-hari yang digunakan oleh penyandang disabilitas tunarungu dan tunawicara. Bahasa isyarat bagi penggunaanya juga dapat digunakan sebagai identifikasi diri dan mencari informasi. Berbeda dengan bahasa lisan, bahasa isyarat dalam

penggunaannya menggunakan gestur yang diperagakan oleh tangan dan dipersepsikan melalui visual atau penglihatan oleh mata. Bahasa isyarat dalam konteks kondisi tubuh diartikan sebagai isyarat tentang kondisi kesehatan yang diderita seperti sakit kepala, kuat, lemah, dan lain sebagainya [6]

B. Flex Sensor

Sensor *flex* bekerja berdasarkan prinsip resistensi variabel, dimana nilai resistensinya berubah seiring dengan derajat tekukan yang diberikan. Komponen utamanya terdiri dari lapisan bahan resistif berbasis karbon yang fleksibel, sehingga mampu menghasilkan respon linier terhadap deformasi mekanis. Ketika sensor dalam keadaan lurus, resistensinya berada pada nilai minimum, sedangkan semakin besar tekukan yang diberikan, resistansinya akan secara meningkat [7]

C. MPU6050

MPU6050 (*Motion Processing Unit*) merupakan modul sensor IMU (*Inertial Measurement Unit*) bekerja dengan menggabungkan *accelerometer* dan *gyroscope* dalam satu chip. Sensor ini bekerja berdasarkan prinsip *Microelectromechanical Systems* (MEMS), dimana komponen mekanis berukuran mikro digunakan untuk mendeteksi perubahan percepatan dan kecepatan sudut. *Accelerometer* pada MPU6050 berfungsi untuk mengukur percepatan linear pada tiga sumbu orthogonal (X, Y, Z) sedangkan *gyroscope* berfungsi untuk mendeteksi kecepatan sudut di sekitar ketiga sumbu tersebut. Data yang dihasilkan oleh sensor ini dapat digunakan untuk menentukan orientasi, gerakan dan gaya gravitasi yang bekerja pada suatu objek [8].

D. ESP32

ESP32 (Espressif System 32) merupakan mikrokontroler yang dikembangkan oleh espressif sistem yang merupakan pengembangan dari seri sebelumnya yaitu ESP8266. Mikrokontroler ini dilengkapi dengan modul (*Wireless Fidelity*) *WI-FI* dan *Bluetooth* yang terintegrasi, sehingga sangat cocok untuk aplikasi *Internet Of Things* (IoT). ESP32 dilengkapi dengan berbagai fitur canggih seperti 18 ADC (*Analog Digital Converter*) yang berfungsi untuk merubah sinyal analog ke digital, 2 *channel* DAC (*Digital Analog Converter*) yang berfungsi untuk merubah sinyal digital ke analog, 16 *channel* PWM (*Pulse Width Modulation*), 20 sensor sentuh, 2 jalur antarmuka UART, I2C, I2S dan SPI [9].

E. LCD I2C

Salah satu fitur utama LCD (*Liquid Crystal Display*) 16x2 I2C adalah integrasinya dengan chip PCF8574 yang berfungsi sebagai antarmuka antara LCD Paralel konvensional dan protocol I2C. dengan demikian, modul ini hanya memerlukan dua jalur komunikasi yaitu SDA (*Serial Data*) dan SCL (*Serial Clock*) untuk mengirim dan menerima data dari mikrokontroler. Hal ini sangat menghemat jumlah pin yang digunakan terutama pada proyek-proyek yang membutuhkan banyak komponen. Selain itu, modul ini dilengkapi dengan potensiometer bawaan untuk mengatur kontras tampilan yang memungkinkan pengguna menyesuaikan kecerahan layar sesuai kebutuhan [10].

F. FCNN

Fully connected neural network (FCNN) merupakan salah satu arsitektur dasar dalam pembelajaran mesin yang terdiri dari lapisan-lapisan neuron yang saling terhubung secara lengkap antar lapisan. Setiap neuron pada lapisan

tertentu terhubung dengan semua neuron pada lapisan berikutnya, sehingga memungkinkan pemrosesan informasi secara hierarkis. Arsitektur ini sering digunakan dalam tugas klasifikasi dan regresi karena kemampuannya untuk memodelkan hubungan non-linear antara input dan output [11].

G. Leaky ReLU

Leaky rectified linear unit (*Leaky ReLU*) adalah pengembangan dari fungsi aktivasi *ReLU* yang dirancang untuk mengatasi masalah “*Dead Neuron*” yang sering terjadi pada jaringan saraf tiruan (JST). Masalah ini muncul ketika neuron tidak merespons input negatif karena gradien yang dihasilkan oleh *ReLU* bernilai nol, sehingga menghambat proses pembelajaran [12].

H. Confusion Matrix

Confusion matrix merupakan salah satu alat evaluasi yang digunakan untuk mengukur kinerja suatu model klasifikasi dalam *machine learning*. Matriks ini menyajikan perbandingan antara hasil prediksi model dengan nilai aktual dari data uji, sehingga dapat memberikan gambaran yang komprehensif mengenai akurasi, presisi, sensitivitas dan performa lainnya [13].

I. Machine Learning

Untuk mengevaluasi kinerja model klasifikasi, beberapa metrik evaluasi digunakan, seperti akurasi (*accuracy*), presisi (*precision*), *recall* dan *F1-score* [14].

Akurasi mengukur seberapa sering model membuat prediksi yang benar secara keseluruhan. Rumusnya adalah :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Atau jika menggunakan multi kelas dapat digunakan rumus:

$$Accuracy = \frac{\sum TP}{total\ sampel} \quad (2)$$

Dimana :

- TP (*True Positive*) : prediksi benar untuk kelas positif.
- TN (*True Negative*) : prediksi benar untuk kelas negatif.
- FP (*False Positive*) : prediksi salah (kelas positif tetapi sebenarnya negatif).
- FN (*False Negative*) : prediksi salah (kelas negatif tetapi sebenarnya positif).
- Total Sampel : Total deteksi yang dilakukan atau total data testing yang dilakukan dari keseluruhan kelas

Presisi mengukur proporsi prediksi positif yang benar dibandingkan dengan total prediksi positif, baik yang benar maupun salah rumusnya adalah :

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

Metriks ini penting ketika biaya dari FP tinggi, misalnya dalam deteksi spam dimana salah satu mengklasifikasikan email normal sebagai spam (FP) sangat merugikan. Hasil dari presisi dapat mengukur seberapa akurat model dalam mengenali satu kelas dan menghindari prediksi yang salah [14].

Recall (sensitivitas) mengukur kemampuan model untuk menemukan semua *instance* positif dalam data. Rumusnya adalah :

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

Recall berguna dalam kasus seperti diagnosis medis, dimana melewatkan kasus positif (FN) dapat berakibat fatal. *Recall* dihitung dengan membagi jumlah TAPI atau prediksi benar

positif dengan jumlah total data yang aktual atau jumlah keseluruhan data yang diuji [14].

F1-score merupakan rata-rata harmonik dari presisi dan *recall*, memberikan keseimbangan antara keduanya. Rumusnya adalah :

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

F1-score sangat berguna ketika perlu mempertimbangkan baik FP maupun FN, terutama dalam data yang tidak seimbang. F1-score digunakan untuk memberikan pandangan keseluruhan tentang kinerja model dengan mempertimbangkan dua pengukuran yaitu *recall* dan *precision*. Nilai hasil pengukuran F1-score yang mendekati 1.0 menandakan model baik dalam memprediksi [14].

Penggunaan rumus-rumus ini sangat penting untuk mengevaluasi kinerja model *machine learning* dalam melakukan prediksi pada kelas yang ditentukan baik kelas tunggal maupun multi kelas. Evaluasi model menggunakan *recall*, *precision*, F1-score dan akurasi merupakan evaluasi untuk model yang tidak terlalu rumit dan penggunaan rumus yang lebih simpel [14].

III. METODE

A. Rancangan Mikrokontroler dan Sistem Sensor

TABEL 1
(SAMBUNGAN PIN FLEX DENGAN ESP32)

Flex Sensor	ESP32
Ibu jari	Pin 33
Jari telunjuk	Pin 35
Jari tengah	Pin 36
Jari manis	Pin 39
Jari Kelingking	Pin 32

Tabel 1 merupakan integrasi pin antara *flex* sensor dengan ESP32, dimana pin pada *flex* sensor yang dimaksud merupakan titik tengah antara pin tegangan pada *flex* dengan resistor yang ada pada rangkaian pembagi tegangan. Pemilihan pin pada ESP32 juga merupakan pin-pin yang tentu sudah *support* atau memiliki fitur ADC.

TABEL 2
(SAMBUNGAN PIN MPU6050 DENGAN ESP32)

Sensor MPU6050	ESP32
Voltage at Common Collector (VCC)	3.3 volt
Ground (GND)	Ground (GND)
Serial Clock (SCL)	22
Serial Data (SDA)	21

Tabel 2 diatas merupakan konfigurasi pin antar komponen juga memerlukan konfigurasi sesuai dengan *default* pada masing-masing komponen. Pada kaki sensor terdapat 4 pin yang mewakili diantaranya VCC, GND, SCL, dan SDA. Kaki pada MPU6050 tersebut dihubungkan dengan pin pada ESP32 dengan mencocokkannya sesuai dengan nama untuk VCC dan GND, VCC disambungkan dengan daya pada 3.3 volt dan terhubung dengan ground. Pemilihan pin SCL dan SDA yang dihubungkan dengan pin *General Purpose Input Output* (GPIO) 22 dan 21 pada ESP dikarenakan pin *default* komunikasi I2C pada ESP32 terletak pada pin tersebut.

TABEL 3
(SAMBUNGAN PIN LCD DENGAN ESP32)

ESP32	LCD I2C
GPIO21	SDA

GPIO22	SCL
3.3 volt	VCC
GND	GND

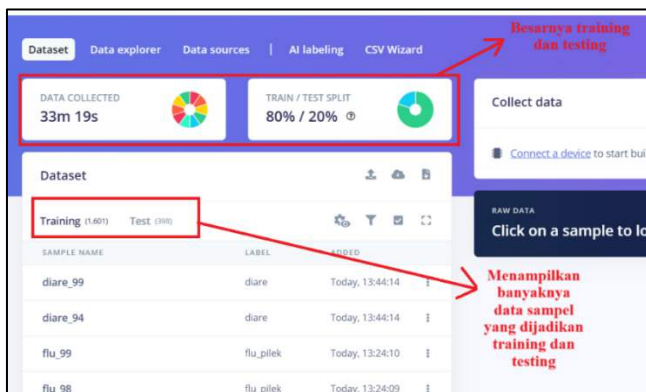
Pada tabel 3 merupakan sambungan antara LCD I2C dengan ESP32 dimana pin SDA dan SCL pada LCD I2C disambungkan dengan pin GPIO 21 dan GPIO 22. Sambungan pin 21 dan 22 ditentukan karena fitur komunikasi serial I2C pada ESP32 hanya terletak pada pin 21 dan 22 yang artinya pin tersebut merupakan pin *default* dari spesifikasi ESP32.

B. Arsitektur Machine Learning

TABEL 4
(PENJELASA NILAI DATA SAMPEL)

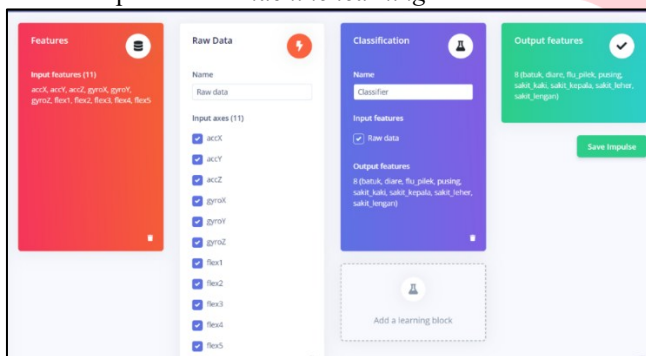
No	Nama label	keterangan
1	accX	Nilai akselerasi sumbu X yang oleh MPU6050
2	accY	Nilai akselerasi sumbu Y yang oleh MPU6050
3	accZ	Nilai akselerasi sumbu Z yang oleh MPU6050
4	gyroX	Nilai giroskop sumbu X yang oleh MPU6050
5	gyroY	Nilai giroskop sumbu y yang oleh MPU6050
6	gyroZ	Nilai giroskop sumbu Z yang oleh MPU6050
7	Flex1	Nilai resistansi pada <i>flex</i> sensor ibu jari
8	Flex2	Nilai resistansi pada <i>flex</i> sensor jari telunjuk
9	Flex3	Nilai resistansi pada <i>flex</i> sensor jari tengah
10	Flex4	Nilai resistansi pada <i>flex</i> sensor jari manis
11	Flex5	Nilai resistansi pada <i>flex</i> sensor jari kelingking
12	label	Nama gerakan bahasa isyarat kondisi tubuh

Tabel 4 Merupakan fitur yang digunakan untuk model dapat mengenali data sampel saat digunakan untuk berlatih dan beruji. Fitur-fitur ini yang nantinya juga digunakan sebagai inputan saat model sudah *dideploy* ke perangkat ESP32. Fitur-fitur ini dideklarasikan berdasarkan penggunaan hasil pembacaan dari modul MPU6050 dan *flex* sensor.



GAMBAR 1
(TRAINING DAN TESTING DATA SAMPEL)

Gambar 1 merupakan data sampel ini secara otomatis akan membagi menjadi data yang digunakan model untuk berlatih dan data yang digunakan untuk diuji. pada gambar 1. Terlihat data sampel yang terkumpul membagi antara *training* sebanyak 80% dan *testing* sebanyak 20%. Terlihat banyaknya data sebanyak 1601 data untuk *training* dan 398 data untuk *testing*. Setelah data sampel diolah, selanjutnya dilakukan pemodelan *machine learning*.



GAMBAR 2
(PARAMETER PEMODELAN)

Pada gambar 2 terlihat jika parameter yang digunakan adalah *features*, *raw data*, dan *Classification*. *Features* merupakan pengaturan untuk data sampel bukan *time series* yang berarti data sampel yang dilakukan tidak dianalisis berdasarkan perubahan waktu.

Features merupakan pengaturan untuk data sampel bukan *time series* yang berarti data sampel yang dilakukan tidak dianalisis berdasarkan perubahan waktu. Pada pengaturan parameter ini juga menampilkan label pada setiap data sampel yang digunakan. Terdapat label *accX* sebagai nilai dari akselerasi MPU6050 pada sumbu X, label *accY* sebagai nilai dari akselerasi MPU6050 pada sumbu Y, label *accZ* sebagai nilai dari akselerasi MPU6050 pada sumbu Z, label *gyroX* sebagai nilai dari giroskop MPU6050 pada sumbu X, label *gyroY* sebagai nilai dari giroskop MPU6050 pada sumbu Y, label *gyroZ* sebagai nilai dari giroskop MPU6050 pada sumbu Z, label *flex1* sebagai nilai dari *flex* sensor pada ibu jari, label *flex2* sebagai nilai dari *flex* sensor pada jari telunjuk, label *flex3* sebagai nilai dari *flex* sensor pada jari Tengah, label *flex4* sebagai nilai dari *flex* sensor pada jari manis, dan label *flex5* sebagai nilai dari *flex* sensor pada jari kelingking.

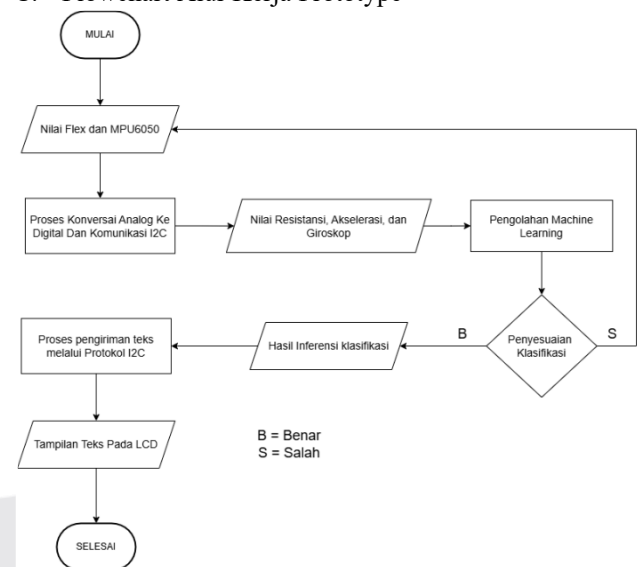
Raw data digunakan untuk pemilihan *block processing*. *Raw data* dipilih karena blok ini tidak mengubah apa pun dari data sampel yang telah dimasukkan, artinya data sampel merupakan data mentah yang digunakan sebagai pemodelan

dalam bentuk aslinya tanpa melewati proses manipulasi apa pun.

Untuk membuat model guna mengklasifikasi bahasa isyarat kondisi tubuh digunakan *learning block FCNN (Fully Connected Neural Networks)*. Penggunaan blok FCNN ini merupakan blok yang berperan sebagai lapisan klasifikasi utama yang mengubah fitur masukan oleh *flex* dan MPU6050 menjadi prediksi kelas batuk, flu, diare, sakit leher, sakit kepala, sakit lengan, sakit kaki, dan pusing. FCNN sangat cocok digunakan untuk data tabular dan fitur numerik atau data dengan fitur yang tidak berhubungan secara spasial seperti nilai yang dikeluarkan oleh sensor *flex* dan MPU6050 karena setiap neuron lapisan FCNN terhubung ke semua neuron lapisan sebelumnya, sehingga dapat mempelajari nilai kompleks seperti pada data sampel yang telah dikumpulkan.

Pada pemodelan juga digunakan aktivasi *Leaky ReLU* karena berhubungan dengan penggunaan FCNN karena fungsi aktivasi *Leaky ReLU* dapat dipakai di lapisan-lapisan FCNN untuk mengatasi masalah neuron yang mati atau tidak belajar pada saat melakukan *training*. Setiap neuron pada lapisan pada lapisan FCNN terhubung ke semua neuron di lapisan sebelumnya, sehingga fungsi aktivasi *Leaky ReLU* sangat penting untuk menjaga agar neuron tetap aktif dan tetap mengalir selama proses pelatihan.

C. Flowchart Alur Kerja Prototype




GAMBAR 3
(FLOWCHART KERJA PROTOTYPE)

Gambar 3 menunjukkan alur kerja keseluruhan dari rancangan sarung tangan pengenalan bahasa isyarat kondisi tubuh. Alur kerja pada sarung tangan dimulai dengan pelekukan *flex* sensor dan modul MPU6050 yang menghasilkan nilai sebagai masukan untuk klasifikasi pada *machine learning*. Nilai yang dapat dibaca oleh *machine learning* adalah nilai masukan yang berbentuk digital sehingga setelah dilakukan penggerakan *flex* dan MPU6050, ESP32 akan terlebih dahulu mengubahnya menjadi nilai digital melalui pin *Analog to Digital Converter (ADC)* yang teintegrasi antara *flex* sensor dengan pin-pin ADC pada ESP32. Selain itu MPU6050 juga dapat disalurkan nilai akselerasi dan giroskopnya melalui konfigurasi serial I2C pada pin ESP32. Dengan begitu tidak ada *raw data* yang diproses oleh *machine learning*. Nilai dari *flex* dan MPU6050 tersebut digunakan sebagai klasifikasi oleh model yang dirancang untuk mengenali gerakan bahasa isyarat. Pada

flowchart terdapat *decision* untuk membedakan dua proses dengan maksud perulangan. Proses pertama dilakukan jika nilai masukan oleh *flex* dan MPU6050 dikenali oleh model maka model dapat mengeluarkan hasil interpretasi yang kemudian disalurkan ke komponen LCD I2C 16x2 agar dapat ditampilkan dalam bentuk teks. Penyaluran hasil pengenalan ini dilakukan dengan komunikasi serial I2C pada LCD 16x2 yang terkonfigurasi dengan pin pada ESP32. Di sisi lain jika nilai masukan oleh *flex* dan MPU6050 tidak dikenali oleh model maka model tidak akan mengeluarkan hasil interpretasi yang kemudian meminta untuk melakukan rekaman ulang dari gerakan untuk menghasilkan nilai masukan yang dapat dikenali oleh model.


IV. HASIL DAN PEMBAHASAN

A. Tampilan *prototype*



GAMBAR 4
(TAMPILAN SARUNG TANGAN)

Gambar 4 merupakan rangkaian yang sudah diimplementasikan ke sarung tangan. Terlihat pada gambar terdapat 5 *flex* sensor yang terhubung ke ESP32 dengan meletakkannya pada ruas-ruas jari dari ibu jari hingga jari kelingking. Kemudian peletakan *board* ESP32 dengan *expansion* diletakkan di atas punggung dari sarung tangan.



GAMBAR 5
(PELETAKAN MPU PADA SARUNG TANGAN)

Sementara pada peletakan modul MPU6050 berada di bawah dari *board* ESP32 seperti terlihat pada gambar 5. Penggunaan modul ini untuk mendeteksi gerakan tangan sehingga peletakkannya sama seperti ESP32 yang akhirnya harus ditumpang tindih dengan ESP32 namun dengan letak yang seperti ini tidak mengganggu kualitas dari pembacaan akselerasi dan *gyroscope* yang dihasilkan oleh modul.

B. Akurasi dan Evaluasi model

Hasil pengujian tingkat akurasi setelah model diterapkan pada ESP32 yang telah dilakukan dapat dilihat pada tabel 5. Hasil pengujian dicatat dalam bentuk *confusion matrix* untuk dapat mengukur akurasi dari sampel yang telah diuji.

Confusion matrix ini digunakan sebagai bahan evaluasi model dalam memprediksi gerakan.

TABEL 5
(*CONFUSION MATRIX* HASIL PENGUJIAN AKURASI)

	Batuk	Diare	Flu pilek	Pusing	Sakit kaki	Sakit kepala	Sakit leher	Sakit lengan
Batuk	30%	0%	0%	0%	0%	0%	70%	0%
Diare	0%	90%	0%	0%	10%	0%	0%	0%
Flu pilek	0%	0%	100%	0%	0%	0%	0%	0%
Pusing	0%	0%	0%	90%	0%	0%	10%	0%
Sakit kaki	0%	0%	0%	0%	100%	0%	0%	0%
Sakit kepala	0%	0%	0%	0%	0%	100%	0%	0%
Sakit leher	0%	0%	0%	0%	0%	0%	100%	0%
Sakit lengan	0%	0%	0%	0%	20%	0%	0%	80%
F1 score	0.46	0.94	1.0	0.94	0.86	1.0	0.70	0.88

Perhitungan:

a. F1-score

1. Kelas Batuk

- TP = 30
- FN = 70
- FP = 0
- TN = 0
- $Recall = \frac{TP}{TP+FN} = \frac{30}{30+70} = \frac{30}{100} = 0.3$
- $Precision = \frac{TP}{TP+FP} = \frac{30}{30+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 0.3}{1.0 + 0.3} = 2 \times \frac{0.3}{1.3} = 0.46$

2. Kelas Diare

- TP = 90
- FN = 10
- FP = 0
- TN = 0
- $Recall = \frac{TP}{TP+FN} = \frac{90}{90+10} = \frac{90}{100} = 0.90$
- $Precision = \frac{TP}{TP+FP} = \frac{90}{90+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 0.90}{1.0 + 0.90} = 2 \times \frac{0.90}{1.90} = 0.94$

3. Kelas Flu Pilek

- TP = 100
- FN = 0
- FP = 0
- TN = 0
- $Recall = \frac{TP}{TP+FN} = \frac{100}{100+0} = \frac{100}{100} = 1.0$
- $Precision = \frac{TP}{TP+FP} = \frac{100}{100+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 1.0}{1.0 + 1.0} = 2 \times \frac{1.0}{2.0} = 1.0$

4. Kelas Pusing

- TP = 90
- FN = 10
- FP = 0
- TN = 0
- $Recall = \frac{TP}{TP+FN} = \frac{90}{90+10} = \frac{90}{100} = 0.90$
- $Precision = \frac{TP}{TP+FP} = \frac{90}{90+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 0.90}{1.0 + 0.90} = 2 \times \frac{0.90}{1.90} = 0.94$

5. Kelas Sakit Kaki

- TP = 100
- FN = 0

- $FP = 10 + 20 = 30$
- $TN = 0$
- $Recall = \frac{TP}{TP+FN} = \frac{100}{100+0} = \frac{100}{100} = 1.0$
- $Precision = \frac{TP}{TP+FP} = \frac{100}{100+30} = 0.76$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{0.76 \times 1.0}{0.76 + 1.0} = 2 \times \frac{0.76}{1.76} = 0.86$

6. Kelas Sakit Kepala

- $TP = 100$
- $FN = 0$
- $FP = 0$
- $TN = 0$
- $Recall = \frac{TP}{TP+FN} = \frac{100}{100+0} = \frac{100}{100} = 1.0$
- $Precision = \frac{TP}{TP+FP} = \frac{100}{100+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 1.0}{1.0 + 1.0} = 2 \times \frac{1.0}{2.0} = 1.0$

7. Kelas Sakit Leher

- $TP = 100$
- $FN = 0$
- $FP = 70 + 10 = 80$
- $TN = 0$
- $Recall = \frac{TP}{TP+FN} = \frac{100}{100+0} = \frac{100}{100} = 1.0$
- $Precision = \frac{TP}{TP+FP} = \frac{100}{100+80} = 0.55$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{0.55 \times 1.0}{0.55 + 1.0} = 2 \times \frac{0.55}{1.55} = 0.70$

8. Kelas Sakit Lengan

- $TP = 80$
- $FN = 20$
- $FP = 0$
- $TN = 0$
- $Recall = \frac{TP}{TP+FN} = \frac{80}{80+20} = \frac{80}{100} = 0.8$
- $Precision = \frac{TP}{TP+FP} = \frac{80}{80+0} = 1.0$
- $F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{1.0 \times 0.8}{1.0 + 0.8} = 2 \times \frac{0.80}{1.80} = 0.88$

Pada pengujian akurasi dilakukan 80 gerakan di antaranya 10 gerakan untuk setiap label. Hasil dari pengujian dapat dilihat pada *confusion matrix* pada tabel 5. Pada matriks tersebut terdapat label kelas dengan struktur baris menunjukkan kelas yang diprediksi oleh model pembelajaran mesin dan struktur kolom menunjukkan kelas yang sebenarnya. Nilai pada diagonal utama dilihat dari kiri atas hingga ke kanan bawah menunjukkan persentase prediksi yang benar untuk setiap kelas. Nilai di luar dari diagonal utama menunjukkan model salah dalam mengklasifikasi gerakan yaitu model mengklasifikasi suatu gerakan menjadi gerakan yang lain.

Pada interpretasi kelas batuk hanya memprediksi sekitar 30% dari 10 gerakan yang dilakukan sementara 70% gerakan batuk lainnya salah diprediksi sebagai sakit leher. Pada pengujian flu pilek model dapat mengklasifikasinya menjadi prediksi benar hingga akurasi 100% dengan artian model tidak mengklasifikasinya menjadi label gerakan lainnya. Pada pengujian label diare, 10 gerakan percobaan dapat diklasifikasi dengan benar sekitar 90 % sementara model salah mengklasifikasi ke dalam label sakit kaki sebanyak

10%. Pada pengujian sakit leher dengan 10 percobaan gerakan, model dapat mengklasifikasi dengan benar dengan 100% gerakan diprediksi pada label sakit leher dengan tidak ada kesalahan klasifikasi. Pada pengujian label sakit lengan, 80% data sakit lengan diprediksi dengan benar sementara 20% diprediksi sebagai klasifikasi sakit kepala. Pada pengujian label sakit kaki, 100% percobaan gerakan sakit kaki diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Pada pengujian label sakit kepala, 100% percobaan gerakan sakit kepala diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Pada pengujian label pusing, 90% percobaan gerakan pusing diprediksi dengan benar sementara 10% diprediksi sebagai diare.

Nilai F1 skor yang dihasilkan untuk sebagian besar kelas berada pada rentang tinggi, seperti pada kelas dengan label flu pilek, diare, sakit lengan, sakit leher, sakit kaki, dan sakit kepala yang menandakan keseimbangan yang baik antara *precision* dan *recall*, kecuali pada kelas batuk yang memiliki nilai F1 skor lebih rendah akibat tingginya tingkat kesalahan klasifikasi. Kesalahan klasifikasi pada batuk disebabkan pola gerakan yang mirip dengan label lainnya seperti pada sakit leher dan lengan.

b. Akurasi keseluruhan

$$\text{Akurasi} = \frac{\sum TP}{\text{total kelas} \times 100} = \frac{30 + 90 + 100 + 90 + 100 + 100 + 100 + 80}{8 \times 100} = \frac{690}{800} = 0.86 \approx 86\%$$

Hasil Akurasi pada model *machine learning* setelah diterapkan pada ESP32 mencapai angka 86% ketepatan secara keseluruhan dimana nilai akurasi ini hampir sama dengan hasil evaluasi model sebelum diterapkan pada ESP32. Nilai ini didapat dengan menjumlahnya *recall* dari masing-masing kelas karena *recall* merupakan hasil prediksi yang berhasil oleh model, dengan membaginya pada jumlah kelas yang dikalikan dengan 100 yang artinya 100 persen data pengujian untuk setiap kelas. Tingkat prediksi yang mencapai angka 86 persen menunjukkan model yang sudah baik untuk mengklasifikasi data hasil masukan dari sensor *flex* dan MPU6050. Hasil ini merupakan rerata akurasi pada kelas yang telah dilakukan pengujian sebanyak 10 kali gerakan untuk setiap kelas.

c. Spesifikasi respon *real-time*

TABEL 6
(HASIL PENGUJIAN RESPON WAKTU)

Percobaan	Label gerakan	Delay (detik)
1	Batuk	0.9
2	Flu Pilek	0.9
3	Diare	0.11
4	Sakit Leher	0.11
5	Sakit Lengan	0.13
6	Sakit Kaki	0.10
7	Sakit Kepala	0.13
8	Pusing	0.111
Rata-rata		0.10

Pengujian *delay* dilakukan untuk melihat bagaimana sarung tangan dapat menerjemahkan gerakan dalam

bentuk *real time*. Pengujian dilakukan dengan bantuan *stopwatch* pada *smartphone*. Pengujian dilakukan peragaan label gerakan dan mencatat hasil pengukuran *delay*. Hasil pengukuran dapat dilihat pada tabel 4.15. Rata-rata dari *delay* yang telah dicatat sebesar 0.10 detik dengan variasi *delay* antara 0.9 hingga 0.13 detik pada beberapa percobaan. Nilai *delay* dengan angka 0.10 detik menunjukkan waktu yang singkat antara gerakan dengan teks yang dikeluarkan. Jeda yang dihasilkan oleh rangkaian sarung tangan cukup cepat dan memenuhi kriteria *real-time*.

V. KESIMPULAN

Berdasarkan design komponen *flex* dan MPU6050 pada sarung tangan dengan prediksi bahasa isyarat kondisi tubuh didapatkan tingkat rerata akurasi dari setiap kelas pada hasil pengujian setelah model diterapkan pada ESP32 mencapai angka 86% akurasi pengenalan yang menandakan rancangan sistem keseluruhan yang cukup baik untuk memprediksi bahasa isyarat kondisi tubuh. *Flex* sensor dan MPU6050 dalam merepresentasikan gerak lekukan jari dan orientasi tangan dapat digunakan sebagai deteksi bahasa isyarat melalui gerak tangan pada sarung tangan yang kemudian dapat diklasifikasikan gesturnya oleh model pembelajaran mesin dengan metode FCNN (*Fully Connected Neural Networks*) menjadi 8 kelas yakni batuk, flu, diare, sakit leher, sakit lengan, sakit kaki, sakit kepala, dan pusing. Berdasarkan pengujian kenyamanan sarung tangan, ukuran tangan pengguna tidak mempengaruhi hasil prediksi sehingga *prototype* dapat digunakan oleh ukuran tangan yang berbeda-beda serta penggunaan LCD menghasilkan keluaran teks yang menjadikan hasil pengenalan bahasa isyarat dapat dibaca oleh tunarungu dan tuna wicara serta orang normal sehingga *prototype* ini memiliki spesifikasi untuk komunikasi dua arah dengan artian antara penyandang dan orang normal dapat menjadi pengguna maupun lawan bicara.

REFERENSI

- [1] N. Khamdi and M. Raja Adrafi, "Sarung Tangan Cerdas Sebagai Translator Bahasa Isyarat untuk Tuna Wicara," *J. Elektro Dan Mesin Terap.*, vol. 8, no. 2, pp. 113–122, Nov. 2022, doi: 10.35143/elementer.v8i2.5485.
- [2] N. I. Pratiwi, I. Widaningrum, and D. Mustikasari, "Perancangan Sistem Deteksi Isyarat BISINDO Dengan Metode Adaptive Neuro-Fuzzy Inference System (ANFIS)," *KomtekInfo*, vol. 6, no. 1, pp. 50–61, May 2019, doi: 10.29165/komtekinfo.v6i1.232.
- [3] W. Ahmad Priadiyatna, H. Hudiono, and A. Rasyid, "RANCANG BANGUN SARUNG TANGAN PINTAR PENERJEMAH BAHASA ISYARAT INDONESIA (BISINDO) BERBASIS IOT," *J. Jartel J. Jar. Telekomun.*, vol. 10, no. 4, pp. 213–219, Dec. 2020, doi: 10.33795/jartel.v10i4.21.
- [4] R. A. Firmansyah and Y. A. Prabowo, "Rancang Bangun Flex Sensor Gloves untuk Penerjemah Bahasa Isyarat Menggunakan K-Nearest Neighbors," *Semin. Nas. Sains Dan Teknol. Terap. VII*, 2019.
- [5] D. Yahya, B. C. Putra, K. Anam, and M. Farkhan, "Alat Penerjemah Bahasa Isyarat Huruf Hijaiyah Menggunakan Sensor Fleksibel dan Mpu 6050 Berbasis Arduino," *BIOS J. Teknol. Inf. Dan Rekayasa Komput.*, vol. 5, no. 1, pp. 46–52, Dec. 2023, doi: 10.37148/bios.v5i1.92.
- [6] S. T. Isma, "MENELITI BAHASA ISYARAT DALAM PERSPEKTIF VARIASI BAHASA," *Kongr. Bhs. Indones.*, pp. 1–14.
- [7] F. Dhilah, D. Kasoni, L. Ningsih, and M. Pardi, "Rancang Bangun Smart Gloves Untuk Penyandang Disabilitas Sensorik Rungu Wicara," *MULTINETICS*, vol. 9, no. 1, pp. 61–70, Jul. 2023, doi: 10.32722/multinetics.v9i1.5779.
- [8] G. Gumilar and H. H. Rachmat, "Sistem Pendeteksi Jatuh Wireless Berbasis Sensor Accelerometer," *TELKA - Telekomun. Elektron. Komputasi Dan Kontrol*, vol. 4, no. 2, pp. 132–141, Nov. 2018, doi: 10.15575/telka.v4n2.132-141.
- [9] W. Patty, S. R. U. A. Sompie, D. J. Mamahit, and L. Gohao, "Rancang Bangun Alat Pemikat Ikan Menggunakan LED RGB Berbasis IoT," *J. Tek. Elektro Dan Komput.*, vol. 10, no. 3, p. 221, Dec. 2021, doi: 10.35793/jtek.10.3.2021.36826.
- [10] H. Suryantoro and A. Budiyo, "PROTOTYPE SISTEM MONITORING LEVEL AIR BERBASIS LABVIEW & ARDUINO SEBAGAI SARANA PENDUKUNG PRAKTIKUM INSTRUMENTASI SISTEM KENDALI," *Indones. J. Lab.*, vol. 1, no. 3, pp. 20–32, 2019.
- [11] L. F. S. Scabini and O. M. Bruno, "Structure and Performance of Fully Connected Neural Networks: Emerging Complex Network Properties," Jul. 29, 2021, *arXiv*: arXiv:2107.14062. doi: 10.48550/arXiv.2107.14062.
- [12] J. Xu, Z. Li, B. Du, M. Zhang, and J. Liu, "Reluplex made more practical: Leaky ReLU," *IEEE*, 2020, doi: 978-1-7281-8086-1.
- [13] I. Hendapratama, I. W. Hamzah, and S. Astuti, "Rancang Bangun Aplikasi Penerjemah SIBI (Sistem Isyarat Bahasa Indonesia) Menggunakan Algoritma Random Forest Classifier," *E-Proceeding Eng.*, vol. 8, no. 6, pp. 3850–3855, 2022.
- [14] S. A. Kaffah and Y. Ramdhani, "Gesture Recognition untuk Deteksi Bahasa Isyarat BISINDO: Pendekatan Mediapipe dan Random Forest," *JOINTECS J. Inf. Technol. Comput. Sci.*, vol. 8, no. 3, p. 105, Sep. 2023, doi: 10.31328/jointecs.v8i3.4813.