

Pengendalian Gerak Robot Beroda Menggunakan Sarung Tangan Pintar dengan Neural Network Backpropagation

^{1,2,a,*}Yunifa Miftachul Arif, ^{2,b}Ahmad Habibil Mustofa, ^{1,c}Khadijah Fahmi Hayati Holle, ^{1,d}Muhammad Ismail Arjun Wibowo, ^{1,e}Miladina Rizka Aziza, ^{1,f}Allin Junikhah, ^{1,g}Novrindah Alvi Hasanah

¹ Teknik Elektro, Universitas Islam Negeri Maulana Malik Ibrahim, Malang

² Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim, Malang

^{a,*}yunif4@ti.uin-malang.ac.id, ^bahmad.mustofa71@gmail.com, ^ckhadijah.holle@uin-malang.ac.id, ^d240904110015@student.uin-malang.ac.id, ^emiladinarizka@uin-malang.ac.id, ^fallin@uin-malang.ac.id, ^gnovrindah@uin-malang.ac.id

Abstract - Conventional remote-controlled robot operation often requires adaptation and prior learning, especially for users unfamiliar with complex button layouts. This study offers a more intuitive solution through a *Hand Gesture Recognition* approach using a smart glove equipped with MEMS sensors, namely an accelerometer and gyroscope. The captured hand movement data is processed using the *Neural Network Backpropagation* method to recognize five types of gestures: stop, forward, backward, turn left, and turn right. The system is implemented on an STM32F10C microcontroller with an NRF24L01 wireless module to transmit classification results to a wheeled robot. Testing was conducted by a single user with ten trials for each gesture. The classification results achieved an average accuracy rate of 82.8%, with fast and stable response to the given commands. These findings demonstrate that robot control can be performed more naturally, efficiently, and responsively through simple hand gestures, showing potential for further development in broader applications.

Keywords —*Hand Gesture Recognition, Neural Network Backpropagation, MEMS Sensor, Robot Control, Microcontroller*

Abstrak— Pengendalian robot berbasis remote control konvensional kerap memerlukan adaptasi dan pembelajaran baru bagi pengguna, khususnya bagi mereka yang belum terbiasa dengan tata letak tombol yang kompleks. Penelitian ini menawarkan solusi yang lebih intuitif melalui pendekatan *Hand Gesture Recognition* berbasis sarung tangan pintar (*smart glove*) yang dilengkapi sensor MEMS berupa akselerometer dan giroskop. Data pergerakan tangan yang diperoleh diolah menggunakan metode *Neural Network Backpropagation* untuk mengenali lima jenis gerakan, yaitu diam, maju, mundur, belok kiri, dan belok kanan. Sistem dikembangkan pada mikrokontroler STM32F10C dengan modul nirkabel NRF24L01 sebagai media transmisi data ke robot beroda. Pengujian dilakukan oleh satu orang pengguna dengan sepuluh kali percobaan untuk setiap gerakan. Hasil klasifikasi menunjukkan tingkat akurasi rata-rata sebesar 82,8%, dengan respon yang cepat dan stabil terhadap perintah yang diberikan. Temuan ini membuktikan bahwa pengendalian robot dapat dilakukan secara lebih natural, efisien, dan responsif hanya dengan gerakan tangan, sehingga berpotensi dikembangkan untuk aplikasi yang lebih luas di masa depan.

Kata Kunci—*Hand Gesture Recognition, Neural Network Backpropagation, Sensor MEMS, Kendali Robot, Mikrokontroler*

I. PENDAHULUAN

Interaksi manusia-robot (Human-Robot Interaction/HRI) semakin berkembang pesat seiring dengan kemajuan teknologi sensor dan algoritma kecerdasan buatan. Salah satu moda interaksi yang semakin diminati adalah pengendalian berbasis *hand gesture* — sistem yang memungkinkan pengguna menggerakkan robot hanya dengan gerakan tangan alami, tanpa perlu antarmuka tombol yang kompleks atau tradisional. Pendekatan ini dinilai lebih intuitif, efisien, dan ramah pengguna, terutama dalam aplikasi tingkat tinggi seperti manufaktur, rehabilitasi, maupun lingkungan industri cerdas.

Sensor MEMS seperti akselerometer dan giroskop telah menjadi fondasi penting dalam sistem pengenalan gerak tangan karena kemampuannya merekam data gerakan secara ringkas, responsif, dan hemat energi. Perkembangan terbaru menunjukkan bahwa integrasi sensor-sensor tersebut pada sarung tangan pintar (*smart glove*) atau perangkat

wearable lainnya dapat menghasilkan sistem kendali robot yang lebih adaptif dan lebih sedikit memerlukan pelatihan pengguna [1].

Secara paralel, kemajuan dalam teknik pengolahan sinyal dan algoritma pembelajaran mendalam (*deep learning*) seperti CNN, LSTM, dan pendekatan hybrid lainnya telah membantu meningkatkan akurasi pengenalan gerak tangan secara signifikan. Misalnya, dakapan EMG (Electromyography) dan IMU (Inertial Measurement Unit) dengan jaringan CNN-LSTM telah mencapai presisi di atas 90 %, mendukung aplikasi real-time di industri [2]. Pendekatan hybrid seperti HGS-SCNN yang menggunakan sEMG juga mampu menembus akurasi sekitar 99,3 %, menjanjikan tingkat keandalan tinggi dalam HRI [3].

Penelitian lain mengeksplorasi metode simulasi untuk merancang smart glove lebih efektif, dengan optimasi penempatan sensor dan pelatihan model deep learning berbasis video yang menawarkan efisiensi biaya dan fleksibilitas [1]. Selain itu, penelitian-penelitian berbasis EMG dengan perangkat seperti *Myo armband* telah menunjukkan keberhasilan dalam mengendalikan lengan robot secara *real-time*, baik untuk pengguna umum maupun penyandang disabilitas, dengan tingkat responsivitas dan akurasi yang memadai [4].

Meskipun sebagian besar studi terkini memanfaatkan EMG-IMU dan deep learning, penggunaan sensor MEMS sederhana yang dikombinasikan dengan mikrokontroler seperti STM32 dan modul nirkabel tetap relevan, terutama untuk tujuan praktis dan efisiensi biaya. Sistem berbasis accelerometer dan giroskop dengan mikrokontroler telah terbukti efektif sebagai alternatif kontrol robot konvensional [5].


Tujuan dari penelitian ini adalah mengembangkan sistem kontrol robot beroda berbasis sarung tangan pintar yang dilengkapi sensor MEMS (akselerometer—giroskop) dan diolah menggunakan metode *Neural Network Backpropagation*. Sistem ini dirancang agar intuitif, responsif, dan mudah dikembangkan lebih lanjut. Melalui pendekatan ini, diharapkan hasil pengenalan gesture tangan dapat mencapai akurasi tinggi, sekaligus menjaga kesederhanaan perangkat keras dan kestabilan sistem secara keseluruhan.

II. METODE PENELITIAN

A. Metode

Metode yang diusulkan dalam penelitian ini menggabungkan sensor MEMS (IMU), perangkat keras mikro-kontroler, algoritma *Neural Network Backpropagation*, dan komunikasi nirkabel untuk mewujudkan sistem kendali robot berbasis pengenalan *hand gestures* secara responsif dan real-time. Pendekatan serupa telah banyak diteliti dalam literatur modern, misalnya: Jiang et al. (2021) mendemonstrasikan sistem wearable berbasis IMU dan deep learning dengan pemrosesan di perangkat (*on-device*) menggunakan FPGA dan MCU, mencapai akurasi pengenalan hingga 97 % tanpa ketergantungan pada komputasi awan [6]; Tchantchane (2023) melakukan tinjauan komprehensif terhadap teknik tangan-noninvasif dalam pengenalan gerakan yang mencakup HGR berbasis sensor wearable dan algoritma ML canggih [7]; serta Liu et al. (2023) memperkenalkan sistem wearable yang mampu mengenali postur tangan dan lintasan gerak dengan akurasi tinggi (~95,85 %) menggunakan kombinasi sensor dan metode klasifikasi modern [8].

Untuk membangun sistem kendali robot berbasis *hand gesture recognition* yang andal, penelitian ini merancang rangkaian proses yang terdiri dari enam tahapan utama: kalibrasi, pelatihan (*training*), input dari pengguna, klasifikasi gerakan, transmisi data, dan eksekusi perintah oleh robot. Setiap tahap memiliki peran spesifik yang saling melengkapi, sehingga data gerakan tangan dapat diolah secara akurat mulai dari tahap akuisisi hingga menjadi aksi fisik robot. Hubungan antar tahapan tersebut divisualisasikan pada diagram sistem di Gambar 1, yang menggambarkan alur kerja secara terstruktur untuk memastikan sistem dapat beroperasi secara real-time, responsif, dan intuitif.



Gambar 1. Diagram Sistem

B. Kalibrasi Sistem

Tahap kalibrasi sistem pada penelitian ini dilakukan dengan memanfaatkan data *training* yang telah disiapkan sebelumnya. Data diperoleh melalui pembacaan sensor giroskop yang diposisikan dan digerakkan secara terkendali untuk memastikan kestabilan serta konsistensi hasil pengukuran. Sensor ini digunakan untuk merekam lima jenis gerakan tangan yang menjadi dasar pengenalan sistem, yaitu posisi diam, maju, mundur, belok kiri, dan belok kanan. Setiap gerakan dilakukan sesuai dengan posisi yang ditunjukkan pada Gambar 2, sehingga data yang terkumpul dapat merepresentasikan karakteristik masing-masing gesture secara akurat. Proses ini bertujuan untuk menghasilkan dataset yang berkualitas tinggi, sehingga pelatihan jaringan saraf tiruan pada tahap berikutnya dapat berjalan optimal dan menghasilkan klasifikasi yang tepat saat sistem digunakan secara real-time.



Gambar 2. Gesture Tangan


Pada *gesture* diam, pertama sensor diletakan pada *gesture* yang stabil dan datar. Sensor dijalankan selama beberapa detik untuk membaca data *gesture* tersebut. Pada waktu itu sensor membaca sebanyak 500 data dan 100 data terakhir diambil sebagai sampel *gesture* diam. Hal ini dilakukan untuk mengambil nilai yang paling stabil dari sensor pada *gesture* tersebut.

Hal yang sama dilakukan untuk *gesture* maju, mundur, kiri dan kanan. Sensor juga didiamkan selama beberapa detik pada *gesture* tersebut. Sensor membaca sebanyak 500 data dan 100 data terakhir diambil sebagai sampel *gesture* tersebut. Pada akhirnya proses ini menghasilkan data sebanyak 500 buah dengan 100 data pada tiap *gesture* yang nantinya akan digunakan sebagai data latih pada proses NN *Training*. Data ini disimpan pada *SDCard* yang terdapat pada modul *memory card* yang dihubungkan ke *microcontroller*. Hal ini dilakukan guna menghemat penggunaan *memory EEPROM microcontroller*.

C. Neural Network Training

Proses Neural Network Training pada sistem ini divisualisasikan dalam bentuk *flowchart* seperti yang ditunjukkan pada Gambar 3. Alur dimulai dari tahap inisialisasi parameter, di mana ditentukan jumlah data latih, struktur jaringan saraf tiruan (jumlah *input layer*, *hidden layer*, dan *output layer*), nilai *learning rate*, *momentum*, bobot awal, serta batas *error* yang diinginkan. Setelah parameter terinisialisasi, sistem memproses data latih yang diperoleh dari sensor untuk tahap *forward propagation*, yaitu menghitung keluaran dari setiap neuron berdasarkan bobot awal dan fungsi aktivasi yang digunakan. Hasil keluaran kemudian dibandingkan dengan target untuk menghitung nilai error. Nilai error ini digunakan dalam tahap *backpropagation* untuk memperbarui bobot jaringan secara iteratif, sehingga model semakin mampu mengenali pola data latih dengan akurasi tinggi. Proses pelatihan berulang hingga nilai error berada di bawah ambang batas yang telah ditentukan atau jumlah *epoch* maksimum tercapai. Dengan metode ini, sistem

menghasilkan model klasifikasi gesture yang siap digunakan pada tahap pengujian dan implementasi real-time untuk kendali robot.



Gambar 3. Flowchart Neural Network Training


Pada percobaan sebelumnya dilakukan simulasi arsitektur NN di Matlab untuk mengetahui arsitektur terbaik yang bisa diaplikasikan berdasarkan tingkat akurasi dan pemakaian kebutuhan komputasi yang bisa dilakukan oleh

microcontroller yang terbatas. Dari hasil tersebut diketahui bahwa arsitektur terbaik untuk sumber daya tersebut adalah dengan 1 buah *hidden layer* dengan 5 *node* dan 1 buah *output layer* untuk menampung 5 kelas klasifikasi.

Sebelum memasuki proses *Training*, dilakukan inisialisasi parameter parameter yang digunakan. Yaitu jumlah data *gesture* yang digunakan untuk data latih (n), jumlah *input layer* yang digunakan pada proses NN Backpro (x), jumlah *hidden layer* yang digunakan pada NN Backpro (z), jumlah *output layer* yang digunakan pada NN Backpro (y), *Learning Rate* yaitu besar kecepatan proses pelatihan pada proses NN Backpro (η), Momentum (α), nilai bobot awal yang akan diatur pada tiap-tiap *input nodes* (ω) dan batas nilai *error* untuk memutuskan NN sudah dinyatakan berhasil atau belum. Selain itu beberapa variabel *temporary* juga di inisialisasi pada bagian ini untuk membantu proses penghitungan di *Neural Network*.

Pada percobaan sebelumnya dilakukan simulasi arsitektur NN dengan parameter-parameter diatas di Matlab. Dari hasil percobaan didapat bahwa semakin besar nilai *Learning Rate* maka semakin cepat proses pelatihan namu

Parameter *Neural Network Backpropagation* yang digunakan pada penelitian ini berupa ; 200 data latih (n), 4 *input layer* (x) yang berasal dari nilai quaternion (w, x, y, z) sensor *gyroscopescope*, 1 *hidden layer* (z) dengan 5 *hidden neuron*, 1 *output layer* (y) dengan 5 kelas klasifikasi, *Learning rate* (η) sebesar 0.01, momentum (α) sebesar 0,9, nilai bobot awal (ω) sebesar 0,5, dan batas nilai *error* sebesar 0,001. Model arsitektur NN *Backpropagation* tersebut selanjutnya ditunjukkan melalui Gambar 4.




Gambar 3. Arsitektur *Neural Network Backpropagation* pada *Gesture Recognition*

D. Input User

Pada proses ini *user* menggunakan *device* kontrol robot pada tangannya. Device ini terdiri dari microcontroller STM32f10 dengan modul sensor *gyroscope* MPU6050 serta modul *radio frequency* nRF24L01. *User* kemudian memeragakan *gesture* arah kendali untuk mengendalikan robot seperti *gesture* yang dipakai pada data latih sebelumnya, yakni *gesture* diam, maju, mundur, kiri dan kanan. Data *gesture* ini kemudian ditangkap oleh sensor *gyroscope* MPU6050. Data ini nantinya akan diklasifikasi menggunakan metode *Neural Network Backpropagation* pada fungsi *testing*. Proses ini akan dijelaskan lebih dalam pada pembahasan selanjutnya.

E. Klasifikasi Neural Network

Proses selanjutnya yaitu Klasifikasi *Neural Network*. Proses ini mengklasifikasi *input user* pada proses sebelumnya menjadi kelas *gesture* gerakan agar bisa dikenali. Alur kerja pada proses ini seperti yang tertera pada *flowchart* yang ditunjukkan melalui Gambar 5.



Gambar 4. *Flowchart* Klasifikasi Neural Network

Proses klasifikasi Neural Network dalam sistem ini divisualisasikan pada Gambar 4. Alur dimulai dari pengambilan data gerakan tangan secara real-time melalui perangkat sensor yang terpasang pada sarung tangan pintar. Data tersebut kemudian dimasukkan ke dalam model Neural Network yang telah dilatih sebelumnya untuk diolah dan menghasilkan nilai keluaran (output). Nilai keluaran ini kemudian dievaluasi menggunakan serangkaian kondisi berbasis ambang batas (threshold) untuk menentukan jenis gesture yang dikenali. Jika nilai output berada pada kisaran tertentu, sistem akan mengklasifikasikannya sebagai salah satu dari lima gesture yang telah ditentukan, yaitu “Diam”, “Maju”, “Mundur”, “Kiri”, atau “Kanan”. Setiap keputusan klasifikasi langsung diterjemahkan menjadi perintah kendali yang dikirimkan ke robot melalui modul komunikasi nirkabel. Dengan alur ini, sistem mampu mengenali

gerakan tangan pengguna dan menerjemahkannya menjadi aksi robot secara cepat dan akurat, mendukung kendali real-time yang responsif dan intuitif.

III. HASIL DAN PEMBAHASAN

A. Implementasi *Hardware*

Pada tahap implementasi, sistem kendali robot yang telah dirancang direalisasikan dalam bentuk perangkat keras (*hardware*) berbasis sarung tangan pintar. Perangkat ini berfungsi sebagai media input utama yang digunakan pengguna untuk mengirimkan perintah gerakan kepada robot melalui pengenalan *gesture* tangan. Gambar 6 memperlihatkan hasil implementasi *remote control* tersebut. Sarung tangan pintar ini dilengkapi dengan mikrokontroler STM32F1xx yang berperan sebagai pusat komputasi, memproses seluruh data masukan dari sensor. Sensor IMU 6 DoF MPU6050 digunakan untuk membaca dan merekam pergerakan tangan secara akurat, sementara modul SD Card berfungsi sebagai penyimpanan data, baik untuk dataset maupun hasil pelatihan jaringan saraf tiruan. Hasil klasifikasi gerakan tangan kemudian dikirimkan secara nirkabel menggunakan modul NRF24L01 ke unit penerima pada robot. Dengan desain ini, perangkat mampu memberikan kendali real-time yang responsif, praktis, dan ergonomis bagi pengguna.



Gambar 6. *Remote control*


Sebagai bagian dari implementasi sistem kendali berbasis *gesture*, unit robot dirancang sebagai perangkat penerima dan eksekutor perintah dari *remote control* yang telah dikembangkan. Robot ini menjadi objek uji untuk memastikan perintah yang dikirim melalui gerakan tangan dapat direspons dengan tepat dan real-time. Gambar 6 memperlihatkan hasil implementasi perangkat keras robot tersebut. Sistem ini menggunakan mikrokontroler Arduino Uno sebagai pusat komputasi yang memproses sinyal perintah dari modul penerima. Perintah tersebut kemudian diteruskan ke driver motor yang berfungsi sebagai pengendali aktuator, mengatur kinerja dua motor DC yang menjadi penggerak utama robot. Desain ini memungkinkan robot bergerak sesuai arah yang diinstruksikan baik maju, mundur, belok kiri, maupun belok kanan, sesuai hasil klasifikasi *gesture* dari sarung tangan pintar. Dengan konfigurasi ini, robot mampu merespons perintah secara cepat dan akurat dalam skenario pengujian.



Gambar 7. Mobile robot

B. Pengujian Sistem


Pengujian sistem dilakukan oleh satu orang penguji dengan prosedur yang dimulai dari tahap kalibrasi hingga proses klasifikasi menggunakan metode Neural Network Backpropagation. Setiap jenis gesture tangan diuji sebanyak sepuluh kali untuk memastikan konsistensi hasil pengenalan. Sebelum proses klasifikasi dapat dijalankan, dilakukan terlebih dahulu tahap training pada model jaringan saraf tiruan. Data seluruh posisi tangan yang sebelumnya tersimpan di modul SD card digunakan sebagai parameter input dan output dalam pelatihan arsitektur Neural Network pada mikrokontroler. Proses training ini dijalankan hingga nilai error mencapai batas yang telah ditentukan, yaitu 0,09. Gambar 8 menunjukkan tampilan proses pelatihan pada mikrokontroler, di mana proses berhenti pada epoch ke-1070 dengan nilai error akhir sebesar 0,08992. Hasil ini menandakan bahwa model telah mencapai tingkat kesalahan yang rendah, sehingga siap digunakan untuk tahap klasifikasi gerakan tangan pada pengujian berikutnya.



Gambar 8. Proses *Training* pada *microcontroller*

Setelah proses pelatihan (*training*) jaringan saraf tiruan selesai dilakukan dan model mencapai tingkat *error* yang telah ditentukan, sistem kemudian diuji untuk memastikan kemampuannya mengenali gerakan tangan secara real-time. Pengujian ini bertujuan untuk mengevaluasi sejauh mana akurasi dan kecepatan respons sistem dalam menerjemahkan gesture pengguna menjadi perintah kendali robot. Pada tahap ini, pengguna memeragakan lima jenis gesture arah kendali, yaitu diam, maju, mundur, belok kiri, dan belok kanan, sesuai dengan pola yang telah digunakan pada proses kalibrasi sebelumnya. Setiap gerakan tangan direkam secara real-time oleh sensor giroskop MPU6050 yang terpasang pada sarung tangan pintar. Data hasil pembacaan sensor kemudian diproses oleh model *Neural*

Network Backpropagation yang telah dilatih, untuk diklasifikasikan ke dalam lima kelas *gesture* tersebut. Sistem menghasilkan nilai keluaran (*output*) berupa angka antara 0 hingga 1, yang mewakili probabilitas atau tingkat keyakinan terhadap masing-masing kelas *gesture*. Gambar 9 menampilkan proses klasifikasi input pengguna secara real-time, di mana sistem secara langsung mengenali *gesture* yang dilakukan dan menerjemahkannya menjadi perintah kendali robot. Hasil ini membuktikan bahwa sistem mampu memberikan respons cepat dan akurat terhadap pergerakan tangan pengguna, sehingga mendukung kendali robot yang intuitif, efisien, dan responsif.



Gambar 9. Proses klasifikasi *input user* secara *realtime*

Tabel hasil output klasifikasi sebanyak 50 kali percobaan pada tiap-tiap *gesture* akan dijabarkan pada tabel dibawah. Presentasi akurasi dari masing-masing data percobaan hasil output kemudian dihitung menggunakan rumus berdasarkan Wachtmeister, Henke, dan Höök (2018).

$$akurasi = \frac{Jumlah\ State\ yang\ benar}{Jumlah\ state\ yang\ diuji} \times 100\% \quad (4.2)$$

Hasil percobaan pada gerakan daim, *user* diminta untuk menggerakkan tangan untuk memberi perintah diam pada robot. Hasil pengujian mendapatkan akurasi seperti berikut.

$$akurasi = \frac{13}{15} \times 100\% = 86,7\% \quad (4.3)$$

Hasil percobaan pada gerakan maju, ketika *user* menggerakkan tangan untuk memberi perintah maju pada robot. Hasil pengujian mendapatkan akurasi seperti berikut.

$$akurasi = \frac{11}{15} \times 100\% = 73,3\% \quad (4.4)$$

Hasil percobaan pada gerakan mundur, ketika *user* menggerakkan tangan untuk memberi perintah mundur pada robot. Hasil pengujian mendapatkan akurasi seperti berikut.

$$akurasi = \frac{12}{15} \times 100\% = 80\% \quad (4.5)$$

Hasil percobaan pada gerakan kiri, ketika *user* menggerakkan tangan untuk memberi perintah belok kiri pada robot. Hasil pengujian mendapatkan akurasi seperti berikut.

$$akurasi = \frac{13}{15} \times 100\% = 86,7\% \quad (4.6)$$

Hasil percobaan pada gerakan kanan, ketika *user* menggerakkan tangan untuk memberi perintah belok kanan pada robot. Hasil pengujian mendapatkan akurasi seperti berikut.

$$akurasi = \frac{13}{15} \times 100\% = 86,7\% \quad (4.7)$$

Nilai klasifikasi tersebut kemudian dikirim ke robot melalui *radio frequency* menggunakan modul nRF24L01. Nilai digunakan oleh robot untuk mengidentifikasi perintah gerak. Hasil akurasi klasifikasi tiap *gesture* kemudian dihitung menggunakan metode MSE seperti pada persamaan 4.2 berikut.

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2 \quad (4.8)$$

$$MSE \text{ akurasi} = \frac{(87 - 100)^2 + (73 - 100)^2 + (80 - 100)^2 + (87 - 100)^2 + (87 - 100)^2}{5} \quad (4.9)$$
$$* 100\%$$

$$MSE \text{ akurasi} = \frac{414}{5} * 100\%$$

$$MSE \text{ akurasi} = 82,8\%$$

Berdasarkan rangkaian pengujian yang telah dilakukan, sistem kendali robot berbasis pengenalan *gesture* tangan ini mampu berfungsi dengan baik dan memberikan respons yang cepat terhadap perintah pengguna. Proses *training* pada jaringan saraf tiruan berhasil mencapai nilai *error* rendah, yang berdampak positif pada akurasi klasifikasi *gesture* saat pengujian real-time. Hasil pengukuran menunjukkan bahwa setiap jenis *gesture* memiliki tingkat akurasi yang cukup tinggi, dengan nilai rata-rata akurasi sebesar 82,8%. Pencapaian ini membuktikan bahwa integrasi sensor IMU, mikrokontroler, serta metode *Neural Network Backpropagation* dapat menghasilkan sistem kendali yang andal dan intuitif. Meskipun demikian, masih terdapat peluang pengembangan lebih lanjut, seperti optimalisasi algoritma, peningkatan jumlah data pelatihan, dan perbaikan desain perangkat keras untuk meningkatkan konsistensi dan akurasi pengenalan gerakan di berbagai kondisi penggunaan. Dengan hasil yang dicapai, sistem ini memiliki potensi besar untuk diimplementasikan pada berbagai aplikasi robotik yang memerlukan kendali berbasis *gesture* secara efisien dan real-time.

IV. KESIMPULAN

Penelitian ini mengusulkan dan mengimplementasikan sistem kendali robot beroda berbasis pengenalan *gesture* tangan menggunakan sarung tangan pintar sebagai media input. Sistem dirancang dengan memanfaatkan sensor IMU MPU6050 untuk membaca gerakan tangan, mikrokontroler STM32F1xx sebagai pusat komputasi, serta metode *Neural Network Backpropagation* untuk mengklasifikasikan lima jenis gerakan, yaitu diam, maju, mundur, belok kiri, dan belok kanan. Hasil pengujian menunjukkan bahwa sistem mampu mengenali *gesture* secara real-time dengan rata-rata akurasi sebesar 82,8%, dan proses *training* berhasil menurunkan nilai *error* hingga di bawah ambang batas yang ditentukan. Keunggulan sistem terletak pada kemudahan penggunaan, sifatnya yang intuitif, serta respons yang cepat dan stabil. Prospek pengembangan di masa depan mencakup optimalisasi algoritma pembelajaran, penambahan variasi dan jumlah data pelatihan, serta peningkatan desain perangkat keras agar kinerja tetap konsisten pada berbagai kondisi. Dengan demikian, sistem ini tidak hanya efektif untuk kendali robot, tetapi juga berpotensi luas untuk diadaptasikan pada aplikasi robotika di bidang industri, rehabilitasi, maupun interaksi manusia-robot.

V. DAFTAR PUSTAKA

- [1] C. Leite, P. Byvshev, H. Mauranen, and Y. Xiao, "Simulation-driven design of smart gloves for gesture recognition," *Sci Rep*, vol. 14, no. 1, p. 14873, Jun. 2024, doi: 10.1038/s41598-024-65069-2.
- [2] E. Kim, J. Shin, Y. Kwon, and B. Park, "EMG-Based Dynamic Hand Gesture Recognition Using Edge AI for Human–Robot Interaction," *Electronics (Basel)*, vol. 12, no. 7, p. 1541, Mar. 2023, doi: 10.3390/electronics12071541.
- [3] M. H. Zafar, E. Falkenberg Langås, and F. Sanfilippo, "Empowering human-robot interaction using sEMG sensor: Hybrid deep learning model for accurate hand gesture recognition," *Results in Engineering*, vol. 20, p. 101639, Dec. 2023, doi: 10.1016/j.rineng.2023.101639.
- [4] T. S. Chu, A. Y. Chua, and E. L. Secco, "A Wearable MYO Gesture Armband Controlling Sphero BB-8 Robot," *HighTech and Innovation Journal*, vol. 1, no. 4, pp. 179–186, Dec. 2020, doi: 10.28991/HIJ-2020-01-04-05.
- [5] P. B. A. Malar.M.B*, R. Praveen, and K. P. Kavipriya, "Hand Gesture Control Robot," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 2, pp. 2814–2818, Dec. 2019, doi: 10.35940/ijitee.B7185.129219.
- [6] W. Jiang *et al.*, "Wearable on-device deep learning system for hand gesture recognition based on FPGA accelerator," *Mathematical Biosciences and Engineering*, vol. 18, no. 1, pp. 132–153, 2021, doi: 10.3934/mbe.2021007.
- [7] R. Tchantchane, H. Zhou, S. Zhang, and G. Alici, "A Review of Hand Gesture Recognition Systems Based on Noninvasive Wearable Sensors," *Advanced Intelligent Systems*, vol. 5, no. 10, Oct. 2023, doi: 10.1002/aisy.202300207.
- [8] Y. Liu *et al.*, "A wearable system for sign language recognition enabled by a convolutional neural network," *Nano Energy*, vol. 116, p. 108767, Nov. 2023, doi: 10.1016/j.nanoen.2023.108767.