

Klasifikasi Skor *Action Research Arm Test* Menggunakan *Wearable sensor* Berbasis IoT dan Random Forest untuk Rehabilitasi Pasca Stroke

Ilmi Suciani Sinambela^{*1}, Muhammad Fikry², Defry Hamdhana³

^{1,2,3}Program Studi Informatika, Fakultas Teknik, Universitas Malikussaleh, Indonesia

Email: ¹ilmi.220170064@mhs.unimal.ac.id, ²muh.fikry@unimal.ac.id, ³defryhamdhana@unimal.ac.id

Abstrak

Pemantauan fungsi ekstremitas atas merupakan bagian penting dalam rehabilitasi pascastroke, tetapi penilaian secara konvensional masih bergantung pada pengamatan tenaga kesehatan dan sulit dilakukan secara berkelanjutan. Penelitian ini bertujuan mengembangkan prototipe *hand wearable sensor* berbasis *Internet of Things* untuk mengklasifikasikan kualitas gerakan tangan berdasarkan skor *Action Research Arm Test* (ARAT). Perangkat dibangun menggunakan mikrokontroler ESP32 dan dua sensor MPU6050 yang ditempatkan pada punggung tangan dan lengan bawah untuk merekam data akselerometer dan giroskop dari 10 subjek sehat pada tujuh gerakan ARAT yang mencakup kategori *gross movement* dan *grip*. Fitur statistik diekstraksi dari sinyal sensor dan ketidakseimbangan data pada setiap kelas ditangani sebelum tujuh model Random Forest dikembangkan secara terpisah untuk memprediksi skor ARAT 0–3 pada setiap gerakan. Hasil pengujian menunjukkan rata-rata akurasi sebesar 89%, presisi makro 0,83, *recall* makro 0,84, dan *F1-score* makro 0,84, dengan model gerakan tangan ke belakang kepala mencapai performa tertinggi (akurasi 94%, *F1-score* 0,90). Hasil tersebut menunjukkan bahwa sistem mampu mengenali pola kualitas gerakan secara menjanjikan sebagai prototipe pendukung pemantauan rehabilitasi, meskipun validasi klinis pada pasien pascastroke masih diperlukan sebelum sistem digunakan dalam pelayanan kesehatan.

Kata kunci: *Action Research Arm Test*, *Internet of Things*, *Random Forest*, *Rehabilitasi Pascastroke*, *Wearable sensor*

Classification of Action Research Arm Test Score Using IoT-Based Wearable sensor and Random Forest for Post-Stroke Rehabilitation

Abstract

Monitoring upper extremity function is an essential component of post-stroke rehabilitation; however, conventional assessment remains dependent on direct observation by healthcare professionals and is difficult to perform continuously. This study aims to develop an Internet of Things based hand wearable sensor prototype for classifying hand movement quality according to the Action Research Arm Test (ARAT) score. The device was constructed using an ESP32 microcontroller and two MPU6050 sensors positioned on the back of the hand and the forearm to record accelerometer and gyroscope data from 10 healthy participants performing seven ARAT movements covering the gross movement and grip categories. Statistical features were extracted from the sensor signals, and class imbalance in the training data was addressed before seven separate Random Forest models were developed to predict ARAT scores ranging from 0 to 3 for each movement. The experimental results achieved an average accuracy of 89%, macro precision of 0.83, macro recall of 0.84, and macro F1-score of 0.84, with the hand to back of head movement model obtaining the best performance (94% accuracy, F1-score of 0.90). These findings indicate that the proposed system can promisingly recognize movement-quality patterns as a prototype for rehabilitation monitoring, although clinical validation involving post-stroke patients is still required before the system can be implemented in healthcare practice.

Keywords: *Action Research Arm Test*, *Internet of Things*, *Post Stroke Rehabilitation*, *Random Forest*, *Wearable sensor*

1. PENDAHULUAN

Stroke merupakan salah satu penyebab utama kematian dan disabilitas jangka panjang yang dapat mengakibatkan penurunan fungsi motorik, terutama pada ekstremitas atas. Gangguan pada lengan dan tangan dapat membatasi kemampuan penyintas stroke dalam melakukan aktivitas sehari-hari, seperti makan,

berpakaian, membawa benda, dan menjaga kebersihan diri [1]. Kondisi tersebut menyebabkan rehabilitasi fungsi ekstremitas atas menjadi bagian penting dalam proses pemulihan pascastroke, yang perlu dilakukan secara berulang, teratur, dan berkelanjutan agar perubahan kemampuan motorik pasien dapat dievaluasi secara objektif [2].

Evaluasi fungsi ekstremitas atas umumnya dilakukan melalui pengamatan langsung oleh dokter, fisioterapis, atau okupasi terapis menggunakan instrumen penilaian klinis, salah satunya *Action Research Arm Test* (ARAT) yang terdiri atas 19 item dalam empat kategori, yaitu *grasp*, *grip*, *pinch*, dan *gross movement*, dengan skor 0–3 pada setiap item [3], [4]. Meskipun memiliki reliabilitas yang baik, pelaksanaan penilaian secara konvensional tetap memerlukan kehadiran tenaga profesional dan pengamatan langsung, sehingga dapat membatasi frekuensi evaluasi, khususnya bagi pasien yang tinggal jauh dari fasilitas rehabilitasi. Keterbatasan fasilitas dan tenaga rehabilitasi di daerah tertentu turut menyebabkan pemantauan perkembangan pasien tidak konsisten, sementara penilaian manual yang bergantung pada observasi pemeriksa berpotensi menimbulkan variasi interpretasi dan belum menggambarkan pola gerakan pasien selama latihan mandiri di rumah. Kondisi tersebut menunjukkan perlunya perangkat pendukung yang dapat merekam karakteristik gerakan secara objektif dan otomatis.

Keterbatasan fasilitas, tenaga rehabilitasi, serta akses layanan di daerah tertentu juga dapat menyebabkan proses pemantauan perkembangan pasien tidak dilakukan secara konsisten. Penilaian manual yang bergantung pada observasi pemeriksa berpotensi menimbulkan variasi interpretasi, terutama ketika dilakukan oleh pemeriksa yang berbeda atau dalam kondisi pengujian yang tidak seragam. Selain itu, penilaian klinis berkala belum sepenuhnya menggambarkan pola gerakan pasien selama latihan mandiri di rumah. Oleh karena itu, diperlukan perangkat pendukung yang dapat merekam karakteristik gerakan secara objektif, mengolah data secara otomatis, dan menampilkan hasil pemantauan melalui sistem yang mudah diakses.

Perkembangan teknologi *wearable sensor* dan *Internet of Things* (IoT) memberikan peluang untuk mengembangkan sistem pemantauan rehabilitasi yang lebih fleksibel. Sensor inersia berupa akselerometer dan giroskop memiliki ukuran kecil, konsumsi daya rendah, dan dapat merekam percepatan, orientasi, serta kecepatan sudut tanpa membatasi gerakan secara signifikan, sehingga data yang direkam dapat dikirim, disimpan, dan ditampilkan secara waktu nyata melalui jaringan nirkabel [5], [6]. Teknologi ini memungkinkan tersedianya informasi kuantitatif mengenai pola gerakan yang sebelumnya hanya dinilai melalui pengamatan visual.

Berbagai penelitian telah menunjukkan potensi pemanfaatan sensor *wearable* dan pembelajaran mesin dalam rehabilitasi stroke, mulai dari identifikasi aktivitas fungsional hingga estimasi skor klinis ekstremitas atas berdasarkan data sensor inersia [7], [8]. Pendekatan berbasis *deep learning* juga telah dikembangkan, antara lain *Deep Neural Network* untuk mengelompokkan tingkat fungsi ekstremitas atas dari data akselerometer [9] dan *Long Short-Term Memory Autoencoder* dengan augmentasi data untuk mengestimasi subskor *Fugl Meyer Assessment* [10], selain pendekatan *serious game* berbasis sensor multimodal untuk mendukung latihan gerakan dan fungsi kognitif pascastroke [11]. Di Indonesia, pengembangan sarung tangan pintar berbasis IoT juga telah dilakukan menggunakan sensor tekuk dan mikrokontroler ESP32 untuk memantau gerakan jari berdasarkan *Manual Muscle Testing* [12].

Walaupun penelitian terdahulu menunjukkan hasil yang menjanjikan, masih terdapat beberapa kesenjangan yang perlu diperhatikan. Sebagian penelitian berfokus pada estimasi skor total, pemantauan aktivitas sehari-hari dalam jangka panjang, penggunaan *deep learning*, atau pengembangan media latihan berbasis permainan. Pendekatan tersebut umumnya membutuhkan konfigurasi komputasi dan data yang relatif besar serta belum selalu diintegrasikan dalam perangkat IoT sederhana yang dapat melakukan akuisisi data, klasifikasi skor tiap gerakan, dan visualisasi hasil dalam satu sistem. Penelitian yang menggunakan standar lain, seperti *Fugl Meyer Assessment* dan *Manual Muscle Testing*, juga belum secara langsung menggambarkan klasifikasi kualitas setiap gerakan berdasarkan skor ARAT 0–3.

Meskipun penelitian terdahulu menunjukkan hasil yang menjanjikan, sebagian besar berfokus pada estimasi skor total, pemantauan aktivitas jangka panjang, pendekatan *deep learning* dengan kebutuhan komputasi dan data yang besar, atau standar penilaian lain seperti *Fugl Meyer Assessment* dan *Manual Muscle Testing* yang belum secara langsung menggambarkan klasifikasi kualitas setiap gerakan berdasarkan skor ARAT 0–3. Pendekatan tersebut juga belum selalu diintegrasikan dalam satu perangkat IoT sederhana yang mampu melakukan akuisisi data, klasifikasi skor tiap gerakan, dan visualisasi hasil secara bersamaan. Selain itu, penerapan sensor *wearable* dalam rehabilitasi masih menghadapi persoalan variasi posisi pemasangan sensor, perbedaan karakteristik gerakan antarindividu, dan ketidakseimbangan jumlah data antarkelas, yang apabila tidak ditangani secara tepat dapat menyebabkan model pembelajaran mesin lebih dominan mengenali kelas dengan jumlah data terbesar [13].

Berdasarkan kesenjangan tersebut, penelitian ini mengembangkan prototipe *hand wearable sensor* berbasis IoT menggunakan mikrokontroler ESP32 dan dua sensor MPU6050 yang ditempatkan pada punggung tangan

dan lengan bawah. Sistem difokuskan pada tujuh item ARAT, yaitu tiga gerakan *gross movement* (tangan ke mulut, tangan ke atas kepala, tangan ke belakang kepala) dan empat gerakan *grip* (menuang air, mengangkat tabung berdiameter 2,25 cm, mengangkat tabung berukuran 1×16 cm, dan memasang *washer* pada baut). Model klasifikasi dikembangkan menggunakan Random Forest karena algoritma ini menggabungkan banyak pohon keputusan berbasis sampel *bootstrap* dan subset fitur acak, sehingga dapat meningkatkan generalisasi dan mengurangi kecenderungan *overfitting* dibandingkan satu pohon keputusan tunggal [14]. Berbeda dari penelitian terdahulu yang menggunakan satu model untuk memprediksi skor keseluruhan atau mengelompokkan tingkat fungsi secara umum, penelitian ini membangun tujuh model Random Forest yang dipisahkan berdasarkan jenis gerakan, sehingga pola sensor dari setiap aktivitas dapat dipelajari secara lebih spesifik sesuai karakteristik arah, amplitudo, dan orientasi masing-masing gerakan. Hasil prediksi selanjutnya divisualisasikan melalui *dashboard* berbasis web sebagai informasi pendukung pemantauan latihan.

Kontribusi utama penelitian ini mencakup tiga aspek: (1) prototipe terintegrasi yang menggabungkan dua sensor MPU6050, ESP32, komunikasi IoT, model Random Forest, dan *dashboard* web; (2) klasifikasi skor ARAT 0–3 secara terpisah pada tujuh gerakan sehingga evaluasi tidak hanya menghasilkan label aktivitas tetapi juga menggambarkan kualitas penyelesaian gerakan; serta (3) penerapan ekstraksi fitur berbasis *sliding window* dan strategi penyeimbangan data bertahap untuk mengurangi dominasi kelas tertentu pada proses pembelajaran model.

Penelitian ini bertujuan merancang dan mengimplementasikan sistem *hand wearable sensor* berbasis IoT untuk merekam pola gerakan tangan secara waktu nyata, menerapkan Random Forest dalam mengklasifikasikan skor pada tujuh gerakan berdasarkan prinsip ARAT, serta mengevaluasi kinerja setiap model menggunakan akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Sistem yang dikembangkan masih berupa prototipe penelitian dengan data dari subjek sehat yang melakukan simulasi tingkatan gerakan, sehingga keluaran sistem belum dapat diposisikan sebagai diagnosis atau pengganti penilaian tenaga kesehatan. Hasil penelitian diharapkan menjadi dasar bagi pengembangan sistem pemantauan rehabilitasi yang selanjutnya dapat diuji melalui validasi klinis pada pasien pascastroke.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dan pengembangan prototipe. Tahapan penelitian mencakup perancangan perangkat keras, akuisisi data gerakan, pembentukan *Dataset*, prapemrosesan, segmentasi sinyal, ekstraksi fitur, penyeimbangan data, pelatihan tujuh model Random Forest, evaluasi kinerja, dan integrasi hasil prediksi dengan *dashboard* web. Alur tersebut dirancang agar data sensor mentah dapat diubah menjadi skor kualitas gerakan yang dapat diamati secara digital.

2.1. Arsitektur Sistem

Sistem Sistem terdiri atas lapisan akuisisi data, pemrosesan, dan antarmuka pengguna. Lapisan akuisisi menggunakan dua sensor MPU6050 dan satu ESP32. MPU6050 dipilih karena menggabungkan akselerometer dan giroskop tiga sumbu dalam satu modul dengan ukuran kecil, konsumsi daya rendah, dan komunikasi I2C yang sederhana untuk diintegrasikan dengan mikrokontroler, sehingga sesuai untuk perangkat *wearable* portabel tanpa membatasi gerakan pengguna. Penggunaan dua sensor, bukan satu, didasarkan pada karakteristik gerakan ARAT yang melibatkan kontribusi pergerakan tangan dan lengan secara bersamaan; sensor tunggal pada satu titik berisiko kehilangan informasi gerak dari segmen tubuh lain yang turut menentukan kualitas penyelesaian tugas. Sensor pertama ditempatkan pada punggung tangan kanan untuk menangkap perubahan posisi dan orientasi tangan, sedangkan sensor kedua ditempatkan pada lengan bawah kanan untuk merekam kontribusi gerakan lengan. Kedua posisi ini dipilih karena merepresentasikan dua segmen yang paling banyak bergerak pada seluruh tujuh item ARAT yang dianalisis, baik pada kategori *gross movement* maupun *grip*, sementara penempatan pada segmen lain seperti lengan atas dianggap kurang relevan karena kontribusi gerakannya minimal pada tugas-tugas tersebut.

ESP32 membaca data kedua sensor melalui komunikasi I2C dan mengirimkannya melalui Wi-Fi ke aplikasi pemrosesan. ESP32 dipilih karena memiliki modul Wi-Fi terintegrasi, dukungan komunikasi I2C ganda, serta harga dan ketersediaan komponen yang relatif terjangkau dibandingkan mikrokontroler lain dengan kapabilitas serupa, sehingga sesuai dengan tujuan penelitian untuk membangun prototipe yang mudah direplikasi. Lapisan pemrosesan menangani penyimpanan, ekstraksi fitur, inferensi Random Forest, dan pencatatan hasil. Lapisan antarmuka berupa *dashboard* web yang menampilkan aktivitas dan skor prediksi.

Setiap MPU6050 menghasilkan tiga kanal akselerometer dan tiga kanal giroskop. Dengan dua sensor, sistem merekam 12 kanal, yaitu $ax1$, $ay1$, $az1$, $gx1$, $gy1$, $gz1$, $ax2$, $ay2$, $az2$, $gx2$, $gy2$, dan $gz2$. Data tersebut merepresentasikan percepatan linier serta kecepatan sudut pada sumbu X, Y, dan Z dari punggung tangan dan lengan bawah.

Tabel 1. Komponen Utama Sistem

Komponen	Jumlah	Fungsi
ESP32	1	Membaca sensor dan mengirim data melalui Wi-Fi
MPU6050	2	Merekam akselerasi dan kecepatan sudut tiga sumbu
Baterai Li-ion 18650	1	Menyediakan daya portabel
Modul pengisian	1	Mengatur pengisian dan perlindungan baterai
Velcro/pengikat	2	Menempatkan sensor pada tangan dan lengan bawah

2.2. Subjek dan Prosedur Pengumpulan Data

Pengumpulan data melibatkan 10 subjek sehat. Seluruh aktivitas dilakukan menggunakan tangan kanan dengan posisi awal yang dibuat seragam. Kursi memiliki tinggi 48 cm dan meja 82 cm untuk mengurangi variasi yang timbul akibat perbedaan postur dan bidang kerja. Dua sensor dipasang pada punggung tangan dan lengan bawah sebelum setiap sesi perekaman.

Subjek diminta melakukan tujuh gerakan yang diadaptasi dari ARAT, terdiri atas tiga gerakan *gross movement* dan empat gerakan *grip*. Setiap gerakan dilakukan dalam empat tingkat kualitas yang diberi skor 0–3. Karena subjek penelitian bukan pasien pascastroke, tingkat kualitas gerakan disimulasikan dengan meminta subjek meniru pola gerakan yang merepresentasikan keterbatasan fungsional pada setiap skor, misalnya memperlambat gerakan, membatasi rentang sudut, atau menghentikan gerakan sebelum selesai. Pendekatan simulasi pada subjek sehat ini lazim digunakan pada tahap awal pengembangan sistem berbasis sensor *wearable* untuk menguji kelayakan teknis ekstraksi fitur dan algoritma klasifikasi sebelum melibatkan populasi klinis, karena memungkinkan pengumpulan data dalam jumlah dan variasi terkontrol tanpa risiko keselamatan atau kelelahan pada pasien pascastroke yang umumnya memiliki keterbatasan fisik. Dengan demikian, hasil pada tahap ini berfungsi sebagai bukti kelayakan (*proof of concept*) bagi arsitektur sistem dan model klasifikasi, bukan hasil diagnosis klinis, dan validasi lebih lanjut pada pasien pascastroke tetap diperlukan sebelum sistem dapat dipertimbangkan untuk pemantauan rehabilitasi yang sesungguhnya.

Tabel 2. Gerakan ARAT yang Dianalisis

No.	Kode	Gerakan	Kategori
1	<i>hand to mouth</i>	Membawa tangan ke mulut	<i>Gross movement</i>
2	<i>hand to top head</i>	Meletakkan tangan di atas kepala	<i>Gross movement</i>
3	<i>hand to back head</i>	Meletakkan tangan di belakang kepala	<i>Gross movement</i>
4	<i>cup</i>	Menuang air dari satu gelas ke gelas lain	<i>Grip</i>
5	<i>big tube</i>	Mengangkat tabung berdiameter 2,25 cm	<i>Grip</i>
6	<i>small tube</i>	Mengangkat tabung berukuran 1 x 16 cm	<i>Grip</i>
7	<i>ring</i>	Memasang washer berdiameter 3,5 cm pada baut	<i>Grip</i>

Tabel 3. Definisi Skor Gerakan

Skor	Kriteria
0	Tidak mampu melakukan gerakan
1	Mampu memulai atau melakukan sebagian gerakan, tetapi tidak menyelesaikannya
2	Mampu menyelesaikan gerakan dalam waktu lebih dari 5 detik
3	Mampu menyelesaikan gerakan dengan baik dalam waktu maksimal 5 detik

2.3. Struktur Dataset dan Prapemrosesan

Dataset terdiri atas 13.968 baris dan 17 kolom, meliputi *subject_id*, *date*, *time*, 12 kanal sensor, *activity*, dan *score*. Label *activity* memuat tujuh gerakan target serta *none* untuk kondisi ketika subjek tidak melakukan gerakan target. Label *score* disimpan dalam rentang 0–3.

Prapemrosesan dilakukan dengan membersihkan nama kolom, mengubah kanal sensor menjadi tipe numerik, mengisi nilai kosong pada *score* dengan 0, mengisi *activity* yang kosong dengan *none*, dan menghapus baris yang masih memiliki nilai tidak valid pada kanal sensor. Tahap ini memastikan bahwa setiap rekaman dapat diproses secara konsisten.

Tabel 4. Struktur *Dataset* Sensor

Kelompok	Kolom	Keterangan
Identitas	<i>subject_id</i>	Identitas subjek
Waktu	<i>date, time</i>	Tanggal dan waktu perekaman
Sensor 1	ax1–az1, gx1–gz1	Akselerasi dan giroskop punggung tangan
Sensor 2	ax2–az2, gx2–gz2	Akselerasi dan giroskop lengan bawah
Label	<i>activity</i>	Jenis aktivitas
Label	<i>score</i>	Skor gerakan 0–3

2.4. Segmentasi Sinyal dengan *Sliding window*

Data sensor merupakan deret waktu sehingga perlu dibagi menjadi segmen yang merepresentasikan potongan gerakan. Segmentasi menggunakan *sliding window* dengan panjang 20 sampel dan langkah pergeseran 5 sampel mengikuti pendekatan umum segmentasi sinyal sensor *wearable* pada literatur terkait [15]. Konfigurasi tersebut menghasilkan tumpang tindih 75% antarjendela berdasarkan rumus persentase tumpang tindih standar, sehingga pola pada batas antarjendela tetap dapat direkam, dengan jumlah jendela total mengikuti banyaknya sampel pada setiap rekaman.

Label aktivitas dan skor pada setiap jendela ditentukan berdasarkan modus, yaitu nilai yang paling sering muncul dalam 20 sampel. Pendekatan ini digunakan untuk mengurangi pengaruh transisi singkat antargerakan.

Tabel 5. Parameter Segmentasi dan Ekstraksi Fitur

Parameter	Nilai
Ukuran jendela	20 sampel
Langkah pergeseran	5 sampel
Tumpang tindih	75%
Jumlah kanal sensor	12 kanal
Fitur per kanal	3 fitur
Total fitur	36 fitur

2.5. Ekstraksi Fitur Statistik

Setiap jendela diubah menjadi vektor fitur untuk mengurangi dimensi temporal dan menangkap karakteristik utama sinyal. Tiga fitur statistik dasar dihitung pada masing-masing kanal, yaitu rata-rata, standar deviasi, dan rentang, mengikuti definisi umum yang lazim digunakan pada analisis sinyal sensor inersia [16]. Rata-rata menggambarkan kecenderungan amplitudo serta arah dominan sinyal selama satu jendela. Standar deviasi merepresentasikan tingkat variasi atau kestabilan gerakan, dengan gerakan yang lebih tidak stabil cenderung menghasilkan nilai standar deviasi lebih tinggi. Rentang menunjukkan selisih nilai maksimum dan minimum pada satu jendela. Karena terdapat 12 kanal dan tiga fitur pada setiap kanal, satu jendela menghasilkan 36 fitur numerik sebagai masukan model.

2.6. Strategi Penyeimbangan Data

Distribusi data tidak seimbang karena jumlah sampel *none* dan jumlah sampel pada setiap skor berbeda. Penelitian menerapkan *combined balancing* dalam dua tahap. Tahap pertama menggunakan *automatic under sampling* terhadap kelas *none*. Untuk setiap gerakan, jumlah sampel *none* dibatasi agar tidak melebihi jumlah sampel gerakan target. Pemilihan sampel dilakukan secara acak dengan *Random_state* 42.

$$N_{none} = \min(N_{none}, N_{gerakan}) \quad (1)$$

Tahap kedua dilakukan setelah data dibagi menjadi 80% data latih dan 20% data uji dengan stratifikasi berdasarkan skor. *RandomOverSampler* hanya diterapkan pada data latih untuk menduplikasi kelas minoritas hingga setara dengan kelas mayoritas. Data uji tidak diseimbangkan agar evaluasi dilakukan pada distribusi yang tidak dimodifikasi dan mencegah kebocoran sampel sintesis atau duplikasi ke tahap pengujian.

Tabel 6. Tahapan *Combined balancing*

Tahap	Teknik	Data	Tujuan
1	<i>Under sampling</i>	Kelas <i>none</i>	Mengurangi dominasi kondisi diam
2	<i>Split 80:20 stratified</i>	Seluruh data	Menjaga proporsi skor
3	<i>Random over sampling</i>	Data latih	Menyeimbangkan skor 0–3
4	Tanpa <i>Balancing</i>	Data uji	Menjaga evaluasi objektif

2.7. Pengembangan Model Random Forest

Random Forest digunakan sebagai pengklasifikasi karena mampu menangani banyak fitur, bekerja baik pada hubungan nonlinier, dan mengurangi varians melalui penggabungan banyak *decision tree*. Setiap pohon dilatih menggunakan sampel *bootstrap* dan subset fitur acak. Prediksi akhir diperoleh melalui *voting* mayoritas dari seluruh pohon.

$$y_{\text{hat}} = \text{mode}\{h_1(f), h_2(f), \dots, h_T(f)\} \quad (2)$$

Pada Persamaan (7), f merupakan vektor 36 fitur, h_t adalah prediksi pohon ke- t , dan T adalah jumlah pohon. Pemisahan *node* menggunakan *Gini impurity* sebagaimana Persamaan (8).

$$G = 1 - \sum_{k=1..K} p_k^2 \quad (3)$$

Tujuh model dibangun secara terpisah untuk *Hand to Mouth*, *hand to top head*, *hand to back head*, *cup*, *big tube*, *small tube*, dan *ring*. Pemisahan model dilakukan karena setiap gerakan memiliki arah, amplitudo, serta pola rotasi yang berbeda. Setiap model menghasilkan skor 0, 1, 2, atau 3.

Tabel 7. *Hyperparameter* Random Forest

Parameter	Nilai
<i>n_estimators</i>	100
<i>criterion</i>	<i>gini</i>
<i>max_features</i>	<i>sqrt</i>
<i>max_depth</i>	<i>None</i>
<i>min_samples_split</i>	2
<i>min_samples_leaf</i>	1
<i>bootstrap</i>	<i>True</i>
<i>Random state</i>	42

2.8. Prosedur Pelatihan dan Inferensi

Pelatihan dilakukan secara terpisah untuk setiap gerakan. Data gerakan target digabungkan dengan sampel *none* yang telah dibatasi, kemudian fitur dan label dipisahkan. Data dibagi menjadi data latih dan data uji, dilanjutkan dengan *over sampling* pada data latih. Model dilatih menggunakan 100 pohon dan disimpan dalam format PKL menggunakan Joblib.

Pada tahap inferensi, data baru diproses menggunakan parameter *sliding window* dan rumus ekstraksi fitur yang sama dengan tahap pelatihan. Model dipilih berdasarkan aktivitas yang dilakukan. Vektor 36 fitur kemudian diproses untuk menghasilkan skor 0–3, dan hasilnya disimpan serta ditampilkan melalui *dashboard* web.

2.9. Evaluasi Kinerja Model

Evaluasi dilakukan pada data uji menggunakan *confusion matrix*, akurasi, presisi, *recall*, dan *F1-score*. Karena klasifikasi melibatkan empat kelas, nilai presisi, *recall*, dan *F1-score* diringkaskan menggunakan *macro average* agar setiap kelas memperoleh bobot yang sama.

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (4)$$

$$\text{Precision} = TP / (TP + FP) \quad (5)$$

$$\text{Recall} = TP / (TP + FN) \quad (6)$$

$$F1 = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (7)$$

$$Macro - F1 = (1 / K) \sum_{k=1..K} F1_k \quad (8)$$

Confusion matrix digunakan untuk melihat distribusi prediksi benar pada diagonal utama dan kesalahan antarkelas di luar diagonal. *Macro-F1* dipilih sebagai metrik penting karena lebih sensitif terhadap performa kelas minoritas dibandingkan akurasi saja.

2.10. Batasan Metodologis

Metode penelitian memiliki beberapa batasan. *Dataset* berasal dari 10 subjek sehat yang mensimulasikan tingkat gerakan, sehingga belum menggambarkan variasi klinis pasien pascastroke. Penelitian hanya menganalisis tujuh dari 19 item ARAT dan belum membandingkan hasil sistem dengan skor yang diberikan oleh tenaga klinis. Selain itu, pembagian data dilakukan secara acak setelah pembentukan *sliding window*. Karena jendela memiliki tumpang tindih 75%, jendela yang berdekatan berpotensi memiliki sebagian sampel mentah yang sama dan masuk ke data latih serta data uji yang berbeda. Kondisi ini dapat membuat hasil pengujian lebih optimistis. Penelitian lanjutan perlu menggunakan pemisahan berbasis subjek, seperti *leave one subject out cross validation*, melibatkan pasien pascastroke, dan menggunakan penilai klinis sebagai pembanding.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi prototipe, hasil pengolahan *Dataset*, kinerja tujuh model Random Forest, validasi fungsional sistem, serta pembahasan terhadap faktor-faktor yang memengaruhi performa. Analisis tidak hanya berfokus pada akurasi, tetapi juga pada *precision*, *recall*, dan *F1-score* makro agar kemampuan model mengenali setiap kelas skor 0–3 dapat dievaluasi secara seimbang.

3.1. Hasil Implementasi Prototipe

Prototipe berhasil mengintegrasikan dua sensor MPU6050, mikrokontroler ESP32, komunikasi Wi-Fi, model Random Forest, basis data, dan *dashboard* web. Sensor pertama ditempatkan pada punggung tangan untuk menangkap perubahan posisi dan orientasi tangan, sedangkan sensor kedua ditempatkan pada lengan bawah untuk merekam kontribusi gerakan lengan. Kombinasi kedua lokasi tersebut menghasilkan 12 kanal data yang terdiri atas enam kanal akselerometer dan enam kanal giroskop.

Pada saat pengujian, ESP32 dapat membaca data kedua sensor dan meneruskannya ke aplikasi pemrosesan. Data baru diproses menggunakan parameter *sliding window* dan ekstraksi fitur yang sama dengan tahap pelatihan. Vektor 36 fitur kemudian dikirim ke model gerakan yang sesuai untuk menghasilkan prediksi skor 0–3. Hasil prediksi dapat disimpan dan ditampilkan pada *dashboard* sehingga pengguna memperoleh informasi mengenai aktivitas yang dilakukan dan kualitas gerakan yang terdeteksi.

Keberhasilan integrasi tersebut menunjukkan bahwa rancangan tidak berhenti pada pengujian model secara luring, tetapi telah direalisasikan sebagai alur sistem dari akuisisi data hingga visualisasi hasil. Meskipun demikian, implementasi ini masih merupakan prototipe penelitian dan belum diuji sebagai perangkat klinis.

3.2. Hasil Pengolahan *Dataset*

Dataset akhir setelah prapemrosesan terdiri atas 13.968 baris dan 17 kolom. Setiap baris memuat identitas subjek, informasi waktu, 12 kanal sensor, label aktivitas, dan skor. Proses *sliding window* menggunakan 20 sampel dengan langkah 5 sampel menghasilkan segmen yang saling tumpang tindih sebesar 75%. Dari setiap segmen diekstraksi rata-rata, standar deviasi, dan rentang pada setiap kanal sehingga diperoleh 36 fitur numerik.

Penggunaan rata-rata membantu menangkap kecenderungan arah dan tingkat sinyal selama gerakan. Standar deviasi menggambarkan kestabilan serta variasi gerak, sedangkan rentang menunjukkan perubahan amplitudo terbesar dalam satu jendela. Ketiga fitur tersebut memberikan representasi ringkas terhadap karakteristik temporal sinyal tanpa harus memasukkan seluruh sampel mentah ke dalam model.


Ketidakseimbangan data ditangani melalui dua tahap. Pertama, jumlah kelas *none* dibatasi agar tidak mendominasi aktivitas target. Kedua, *RandomOverSampler* diterapkan hanya pada data latih setelah pembagian 80:20. Pendekatan ini mempertahankan data uji dalam kondisi tidak dimodifikasi dan mengurangi risiko hasil evaluasi yang terlalu dipengaruhi oleh duplikasi sampel.

3.3. Hasil Evaluasi Tujuh Model Random Forest

Pengujian dilakukan secara terpisah terhadap tujuh model gerakan. Secara keseluruhan, model mencapai rata-rata akurasi 0,89, *precision* makro 0,83, *recall* makro 0,84, dan *F1-score* makro 0,84. Nilai tersebut menunjukkan bahwa model mampu melakukan klasifikasi multikelas dengan performa yang relatif konsisten, walaupun terdapat variasi antarjenis gerakan.

Tabel 8. Rekapitulasi Performa Ketujuh Model Random Forest

No.	Model Gerakan	Sampel	Akurasi	<i>Precision</i> Makro	<i>Recall</i> Makro	<i>F1-score</i> Makro
1	<i>Hand to Mouth</i>	250	0.89	0.81	0.84	0.82
2	<i>Hand to Back Head</i>	276	0.94	0.90	0.90	0.90
3	<i>Hand to Top Head</i>	247	0.84	0.73	0.73	0.73
4	<i>Small Tube</i>	251	0.91	0.85	0.89	0.87
5	<i>Big Tube</i>	266	0.89	0.85	0.81	0.83
6	<i>Cup</i>	235	0.89	0.86	0.82	0.83
7	<i>Ring</i>	245	0.88	0.82	0.80	0.81
	Rata-rata keseluruhan	253	0.89	0.83	0.84	0.84



Gambar 1. Perbandingan Kinerja Ketujuh Model Random Forest

Sebagaimana ditunjukkan pada Tabel 8 dan Gambar 1, terdapat kesenjangan performa yang jelas antara gerakan *gross movement* beramplitudo besar dan gerakan *grip* yang membutuhkan kontrol motorik halus. *Hand to Back Head* secara konsisten unggul pada keempat metrik karena melibatkan perubahan orientasi tangan dan lengan yang besar, sehingga fitur rata-rata, variasi, dan rentang dapat menangkap perbedaan antarskor secara lebih tegas dibandingkan gerakan lain. Sebaliknya, *Hand to Top Head* menjadi satu-satunya model dengan *precision* dan *recall* makro yang setara persis (0,73), pola yang berbeda dari keenam model lainnya yang selalu menunjukkan selisih antara *precision* dan *recall* mengindikasikan bahwa kesalahan pada gerakan ini bukan didominasi oleh satu jenis kesalahan (positif keliru atau sampel tidak terdeteksi), melainkan tersebar merata di kedua sisi, kemungkinan akibat variasi sudut siku, rotasi bahu, dan lintasan tangan yang lebih bebas pada gerakan tersebut.

Pola yang lebih menarik justru terlihat pada kelompok gerakan *grip* ketiga model dengan akurasi identik (*Hand to Mouth*, *Big Tube*, *Cup*, masing-masing 0,89) menghasilkan *F1-score* makro yang berbeda (0,82; 0,83; 0,83). Hal ini menegaskan temuan metodologis penting bagi interpretasi hasil penelitian ini akurasi tunggal tidak cukup merepresentasikan kualitas klasifikasi pada kelas yang tidak seimbang, dan *F1-score* makro perlu menjadi acuan utama karena memberi bobot setara pada keempat skor. Sementara itu, *Ring* dan *Hand to Top Head* dua gerakan dengan amplitudo gerak relatif kecil dan ruang gerak yang lebih bebas secara anatomis justru menempati posisi terbawah pada *F1-score* makro (0,81 dan 0,73), memperkuat indikasi bahwa amplitudo gerak dan konsistensi lintasan, bukan jenis kategori ARAT (*gross movement* vs *grip*) semata, menjadi faktor pembeda utama tingkat kesulitan klasifikasi pada sistem ini.

3.4. Analisis Confusion Matrix

Confusion matrix pada setiap model menunjukkan bahwa mayoritas prediksi berada pada diagonal utama, konsisten dengan rentang akurasi yang telah dilaporkan pada Tabel 8. Pola kesalahan klasifikasi cenderung

terkonsentrasi pada pasangan skor yang berdekatan, yaitu skor 1–2 dan skor 2–3, karena tingkat kemampuan yang berdekatan dapat menghasilkan pola percepatan dan rotasi yang serupa, dengan pembeda utama berupa durasi penyelesaian, kelengkapan lintasan, atau kestabilan gerakan yang tidak selalu tertangkap kuat oleh fitur statistik berbasis jendela. Skor 0 dan 1 berpotensi saling tertukar ketika subjek hanya menghasilkan gerakan awal beramplitudo sangat kecil yang menyerupai sinyal keadaan diam, sedangkan skor 2 dan 3 lebih dibedakan oleh waktu penyelesaian dan kelancaran gerakan dibanding magnitudo sinyal itu sendiri.

Pola pemisahan kelas pada *confusion matrix* sejalan dengan temuan di Tabel 8 yaitu model dengan *F1-score* makro tertinggi (*Hand to Back Head*) menunjukkan distribusi kesalahan paling minim, sedangkan model dengan *F1-score* makro terendah (*Hand to Top Head*) menunjukkan penyebaran kesalahan paling luas antarkelas yang berdekatan. Hasil ini menunjukkan bahwa pengembangan selanjutnya perlu mempertimbangkan fitur tambahan, seperti energi sinyal, korelasi antarsumbu, sudut orientasi, kecepatan puncak, durasi gerakan, atau model temporal, untuk memperkuat pemisahan pada kelas-kelas yang berdekatan.

3.5. Validasi Fungsional Prediksi pada *Subject Testing*

Validasi fungsional dilakukan dengan menjalankan data pengujian melalui alur inferensi sistem dan mengamati kesesuaian keluaran pada *dashboard*. Pengujian mencakup tujuh aktivitas dan empat tingkat skor. Sistem dapat menerima data sensor, membentuk jendela, mengekstraksi 36 fitur, memilih model sesuai aktivitas, dan menampilkan skor prediksi.

Tampilan hasil pengujian pada skripsi memperlihatkan bahwa skor 0, 1, 2, dan 3 dapat dihasilkan untuk setiap aktivitas, meliputi *Hand to Mouth*, *Hand to Back Head*, *Hand to Top Head*, *Small Tube*, *Big Tube*, *Cup*, dan *Ring*. Hasil tersebut membuktikan bahwa model yang tersimpan dapat diintegrasikan ke dalam aplikasi dan digunakan untuk inferensi, bukan hanya dievaluasi melalui notebook atau lingkungan pelatihan.

Validasi ini bersifat fungsional dan belum merupakan validasi klinis. Kesesuaian keluaran sistem belum dibandingkan secara langsung dengan skor yang diberikan oleh fisioterapis atau okupasi terapis pada pasien pascastroke. Oleh sebab itu, hasil validasi digunakan untuk membuktikan bahwa alur teknis sistem bekerja, sedangkan validitas klinis memerlukan penelitian lanjutan.

3.6. Pembahasan

3.6.1. Kontribusi Kombinasi Akselerometer dan Girooskop

Akselerometer dan girooskop memberikan informasi yang saling melengkapi. Akselerometer menangkap perubahan percepatan linier serta pengaruh gravitasi, sedangkan girooskop mengukur kecepatan sudut. Pada gerakan rehabilitasi, dua subjek dapat memiliki arah perpindahan yang serupa tetapi berbeda dalam rotasi pergelangan atau lengan. Penggunaan kedua jenis sinyal memungkinkan model membedakan perubahan posisi sekaligus orientasi.

Penempatan sensor pada punggung tangan dan lengan bawah juga meningkatkan cakupan informasi gerak. Sensor tangan lebih sensitif terhadap perubahan lokal pada tangan, sedangkan sensor lengan bawah merepresentasikan pergerakan segmen proksimal. Kombinasi tersebut penting terutama pada aktivitas *gross movement* yang melibatkan koordinasi bahu, siku, lengan bawah, dan tangan.

3.6.2. Pengaruh Model Terpisah untuk Setiap Gerakan

Penggunaan tujuh model terpisah memungkinkan setiap Random Forest mempelajari pola yang lebih spesifik. Strategi ini mengurangi kompleksitas dibandingkan satu model yang harus membedakan jenis aktivitas sekaligus skor. Hasil evaluasi yang relatif tinggi menunjukkan bahwa pemisahan model sesuai aktivitas merupakan pendekatan yang sesuai untuk prototipe.

Namun, arsitektur tersebut memerlukan informasi aktivitas sebelum model skor dipilih. Dalam implementasi penuh, sistem membutuhkan mekanisme pemilihan aktivitas oleh pengguna atau model pengenalan aktivitas pada tahap pertama. Alternatif pengembangan adalah model hierarkis: model pertama mengenali aktivitas, kemudian model kedua memprediksi skor.

3.6.3. Pengaruh *Combined balancing*

Kombinasi *under sampling* dan *over sampling* membantu mengurangi dominasi kelas *none* serta meningkatkan representasi skor minoritas. Penerapan *over sampling* hanya pada data latih merupakan keputusan penting karena data uji harus tetap mencerminkan sampel yang tidak dimodifikasi. Rata-rata *recall* makro 0,84

menunjukkan bahwa model tidak hanya mengikuti kelas mayoritas, tetapi mampu mendeteksi sebagian besar sampel dari seluruh kelas.

Meskipun demikian, *RandomOverSampler* menggandakan sampel yang sudah ada dan tidak menciptakan variasi baru. Jika data awal pada suatu kelas memiliki variasi terbatas, model dapat mempelajari pola yang terlalu spesifik. Penelitian berikutnya dapat membandingkan *class weighting*, SMOTE yang sesuai untuk data fitur, atau penambahan data dari subjek baru.

3.6.4. Perbandingan Antarmodel dan Implikasi

Perbedaan kinerja antaraktivitas menunjukkan bahwa tingkat kesulitan klasifikasi dipengaruhi oleh karakteristik biomekanik gerakan. Gerakan dengan amplitudo besar dan lintasan yang konsisten, seperti *Hand to Back Head*, lebih mudah dipisahkan. Sebaliknya, gerakan dengan variasi strategi tubuh atau amplitudo kecil, seperti *Hand to Top Head* dan *Ring*, menghasilkan fitur yang lebih tumpang tindih.

Hasil rata-rata akurasi 0,89 dan *F1-score* makro 0,84 cukup untuk menunjukkan kelayakan teknis awal. Namun, angka tersebut belum boleh ditafsirkan sebagai akurasi penilaian klinis ARAT. *Dataset* berasal dari subjek sehat yang melakukan simulasi skor, sehingga distribusi gerakan dapat berbeda dari pasien dengan spastisitas, tremor, kelemahan, kompensasi trunk, atau keterbatasan rentang sendi.

3.6.5. Perbandingan dengan Penelitian Sejenis

Dibandingkan dengan penelitian sejenis, performa sistem ini berada pada posisi yang kompetitif. Ukey et al. melaporkan akurasi 97% untuk mengelompokkan 211 subjek ke dalam lima kategori keparahan berdasarkan rentang skor ARAT total dari data akselerometer 24 jam menggunakan *deep neural network* [9]. Angka ini secara nominal lebih tinggi dari rata-rata akurasi 89% pada penelitian ini, namun kedua tugas tidak setara: Ukey et al. mengklasifikasikan keparahan secara global dengan rentang skor yang lebar dan jarang tumpang tindih, sedangkan penelitian ini mengklasifikasikan skor 0–3 per gerakan secara terpisah, dengan batas antarkelas yang jauh lebih berdekatan.

Perbandingan yang lebih relevan secara desain adalah penelitian Li et al., yang juga melibatkan subjek sehat mensimulasikan kualitas gerakan menyerupai pascastroke menggunakan IMU dan model LSTM [17]. Pada partisipan yang belum pernah dilihat model (*between-participant*), akurasi mereka hanya 58,4–84,9%, jauh di bawah rentang 84–94% pada penelitian ini. Namun pada partisipan yang datanya turut dilatih (*within-participant*), akurasi mereka naik menjadi 87,4–94,8%, mendekati performa penelitian ini. Kesenjangan ini relevan dengan keterbatasan validasi pada penelitian ini sendiri, karena pembagian data secara acak pada level sampel berpotensi membuat performa lebih optimistis daripada jika diuji pada subjek yang benar-benar baru.

Secara keseluruhan, pendekatan multi-model Random Forest pada penelitian ini terbukti kompetitif untuk tugas klasifikasi yang lebih granular dibandingkan kedua studi tersebut, serta unggul dari segi efisiensi komputasi karena tidak memerlukan arsitektur *deep learning*, sehingga lebih sesuai untuk perangkat IoT berdaya rendah seperti ESP32 yang digunakan pada prototipe ini.

3.6.6. Keterbatasan dan Risiko Generalisasi

Keterbatasan utama penelitian adalah jumlah subjek yang masih kecil dan belum melibatkan pasien pascastroke. Skor yang digunakan merupakan adaptasi berdasarkan simulasi kemampuan gerak, bukan hasil penilaian klinis independen. Penelitian juga hanya mencakup tujuh item ARAT dari total 19 item, sehingga keluaran tidak dapat dianggap sebagai skor ARAT penuh.

Selain itu, segmentasi menggunakan tumpang tindih 75% dan pembagian data secara acak dapat menyebabkan jendela yang berdekatan dan berbagi sebagian sampel mentah terdistribusi ke data latih dan data uji. Kondisi ini berpotensi menghasilkan estimasi performa yang lebih optimistis. Oleh karena itu, evaluasi selanjutnya sebaiknya menggunakan pemisahan berbasis subjek, *group split*, atau *leave one Subject out cross validation*.

Performa *real-time* juga dapat dipengaruhi oleh pergeseran posisi sensor, perbedaan kekencangan pengikat, kalibrasi, latensi jaringan, dan variasi posisi awal. Standardisasi pemasangan sensor, kalibrasi sebelum penggunaan, serta pengujian ketahanan sistem perlu dilakukan sebelum implementasi pada lingkungan klinis atau rumah.

3.6.7. Kesiapan Implementasi dan Arah Pengembangan

Dari sisi teknis, prototipe telah menunjukkan alur lengkap dari akuisisi hingga visualisasi hasil. Komponen yang digunakan relatif terjangkau dan mudah diperoleh, sehingga sistem berpotensi dikembangkan sebagai

perangkat pemantauan latihan berbasis rumah. *Dashboard* juga memungkinkan hasil disimpan sebagai riwayat yang dapat digunakan untuk melihat perkembangan dari waktu ke waktu.

Kesiapan klinis masih memerlukan validasi yang lebih ketat. Penelitian lanjutan perlu melibatkan pasien pascastroke dengan tingkat gangguan yang beragam, penilaian simultan oleh tenaga klinis, analisis agreement antara prediksi dan skor *rater*, serta evaluasi reliabilitas antarsesi. Pengembangan juga dapat mencakup seluruh 19 item ARAT, model pengenalan aktivitas otomatis, estimasi durasi gerak, pemantauan kompensasi tubuh, dan umpan balik latihan secara langsung.

4. KESIMPULAN

Penelitian ini berhasil menghasilkan prototipe *hand wearable sensor* berbasis Internet of Things yang mengintegrasikan mikrokontroler ESP32, dua sensor MPU6050, model Random Forest, basis data, dan *dashboard* web untuk mengklasifikasikan kualitas tujuh gerakan yang diadaptasi dari *Action Research Arm Test*. Hasil pengujian menunjukkan bahwa pola kinematik dari sensor inersia dapat digunakan untuk membedakan tingkat kualitas gerakan dengan kinerja yang konsisten antarggerakan, sehingga sistem ini memiliki kelayakan teknis sebagai prototipe pendukung pemantauan rehabilitasi berbasis IoT yang sederhana dan terjangkau. Meskipun demikian, hasil ini belum dapat diposisikan sebagai pengganti penilaian klinis, karena dataset berasal dari subjek sehat yang mensimulasikan skor, hanya mencakup sebagian item ARAT, dan belum divalidasi terhadap penilaian fisioterapis pada pasien pascastroke. Penelitian selanjutnya perlu melibatkan pasien dengan tingkat gangguan motorik yang beragam, menerapkan pemisahan data berbasis subjek, memperluas cakupan item ARAT, serta menguji reliabilitas, validitas, dan ketahanan sistem dalam penggunaan nyata sebelum diadopsi pada layanan rehabilitasi klinis.

DAFTAR PUSTAKA

- [1] A. A. Zainuddin *et al.*, "The major risk factor of stroke across Indonesia; a nationwide geospatial analysis of universal health coverage program," *Arch. Public Heal.*, vol. 83, no. 1, 2025, doi: 10.1186/s13690-025-01613-4.
- [2] A. Bhalla, L. Clark, R. Fisher, and M. James, "The new national clinical guideline for stroke: an opportunity to transform stroke care," *Clin. Med. (Northfield. Ill.)*, vol. 24, no. 2, p. 100025, 2024, doi: 10.1016/j.clinme.2024.100025.
- [3] L. Daghsen *et al.*, "Evaluation of a shortened version of the Action Research Arm Test (ARAT) for upper extremity function after stroke: The Mini-ARAT," *Clin. Rehabil.*, vol. 36, no. 9, pp. 1257–1266, 2022, doi: 10.1177/02692155221097322.
- [4] J. Fernández-Solana *et al.*, "Psychometric Properties of the Action Research Arm Test (ARAT) Scale in Post-Stroke Patients—Spanish Population," *Int. J. Environ. Res. Public Health*, vol. 19, no. 22, p. 14918, 2022, doi: 10.3390/ijerph192214918.
- [5] L. Zhou *et al.*, "Monitoring and Visualizing Stroke Rehabilitation Progress using Wearable Sensors," *2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, pp. 1–6, 2024. doi: 10.1109/embc53108.2024.10782489.
- [6] P. Maceira-Elvira, T. Popa, A.-C. Schmid, and F. C. Hummel, "Wearable technology in stroke rehabilitation: towards improved diagnosis and treatment of upper-limb motor impairment," *J. Neuroeng. Rehabil.*, vol. 16, no. 1, 2019, doi: 10.1186/s12984-019-0612-y.
- [7] C. Werner *et al.*, "Using Wearable Inertial Sensors to Estimate Clinical Scores of Upper Limb Movement Quality in Stroke," *Front. Physiol.*, vol. 13, 2022, doi: 10.3389/fphys.2022.877563.
- [8] I. Boukhenoufa, X. Zhai, V. Utti, J. Jackson, and K. D. McDonald-Maier, "Wearable sensors and machine learning in post-stroke rehabilitation assessment: A systematic review," *Biomed. Signal Process. Control*, vol. 71, p. 103197, 2022, doi: 10.1016/j.bspc.2021.103197.
- [9] J. Ukey, C. Rogers, S. Uhlrich, M. Akcakaya, and A. Sethi, "International Journal of Medical Informatics Enhancing stroke recovery assessment: A machine learning approach to real-world hand function analysis," *Int. J. Med. Inform.*, vol. 204, no. June, p. 106077, 2025, doi: 10.1016/j.ijmedinf.2025.106077.
- [10] C. Yang *et al.*, "Perspectives of users for a future interactive wearable system for upper extremity rehabilitation following stroke: a qualitative study," *J. Neuroeng. Rehabil.*, vol. 20, no. 1, 2023, doi: 10.1186/s12984-023-01197-6.
- [11] S. Selviana, M. Subito, R. Fauzi, and A. Alamsyah, "RANCANG BANGUN ALAT MONITORING

-
- PERKEMBANGAN PASIEN PASCA STROKE BERBASIS IoT (INTERNET of THINGS),” *Foristek*, vol. 11, no. 2, 2021, doi: 10.54757/fs.v11i2.107.
- [12] K. Boardsworth *et al.*, “Upper limb robotic rehabilitation following stroke: a systematic review and meta-analysis investigating efficacy and the influence of device features and program parameters,” *J. Neuroeng. Rehabil.*, vol. 22, no. 1, 2025, doi: 10.1186/s12984-025-01662-4.
- [13] M. Fikry, Bustami, and E. Suzanna, “IOT-Based Environmental Monitoring and Its Implications For Student Mental Health,” *Rev. Gestão Soc. e Ambient.*, vol. 19, no. 2, p. e011183, 2025, doi: 10.24857/rgsa.v19n2-022.
- [14] Y. Susanthi, A. Darmawan, and S. B. Suryadi, “Alat Pengenal Gerakan Tangan Menggunakan Algoritma Artificial Neural Network Berbasis ESP32 dan Platform Edge Impulse,” *Techné J. Ilm. Elektrotek.*, vol. 23, no. 1, pp. 77–94, 2024, doi: 10.31358/techne.v23i1.434.
- [15] N. Alhammad, “applied sciences Dynamic Segmentation for Physical Activity Recognition Using a Single Wearable Sensor,” 2021.
- [16] T. Accelerometers, M. Bennasar, B. A. Price, D. Gooch, and A. K. Bandara, “Significant Features for Human Activity Recognition Using,” 2022.
- [17] M. Li *et al.*, “Application of Deep Learning Algorithm to Monitor Upper Extremity Task Practice,” pp. 1–16, 2023.