Klasifikasi Aktivitas Manusia Menggunakan Algoritma K-Nearest Neighbor Berbasis Internet Of Things

Dimas Febrianto
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
dimasfebrianto@student.telkomuniversity

Kharisma Monika Dian Pertiwi
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
kharismamonikadp@telkomuniversity.ac.id

Yasinta Romadhona
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
yasintaromadhona@telkomuniversity.ac.id

***Abstract*—Perkembangan *Internet of Things* (IoT) mendorong pemanfaatan perangkat *wearable* untuk pemantauan aktivitas manusia secara *real-time*. Namun, pengembangan sistem yang mampu mengintegrasikan data gerakan dan detak jantung dengan proses klasifikasi yang sederhana, efisien, serta mendukung pembentukan dataset secara terintegrasi masih menjadi tantangan. Penelitian ini bertujuan mengembangkan sistem klasifikasi aktivitas manusia berbasis IoT menggunakan mikrokontroler ESP32, sensor MPU6050, dan *Pulse* Sensor dengan algoritma *K-Nearest Neighbor* (KNN). Sistem melakukan akuisisi data sensor, mengirimkan data melalui protokol MQTT ke server, kemudian melakukan *preprocessing*, pelatihan model, dan evaluasi menggunakan *Python Notebook*. Dataset diperoleh dari 15 partisipan dengan total 13.410 sampel yang mencakup aktivitas duduk, berjalan, dan berlari. Tahap *preprocessing* meliputi imputasi nilai BPM, penghapusan *outlier*, dan normalisasi fitur sehingga diperoleh tiga fitur utama, yaitu *accel_stddev*, *gyro_stddev*, dan *bpm_filled*. Hasil pengujian menunjukkan bahwa model memperoleh nilai K optimal sebesar 18 dengan akurasi 83,69%, *precision* 84,06%, *recall* 83,69%, dan *F1-score* 83,81%. Selain menghasilkan performa klasifikasi yang baik, sistem yang dikembangkan mampu melakukan akuisisi data sensor, komunikasi MQTT, dan pemantauan aktivitas secara *real-time* melalui dashboard web dan layar OLED. Hasil penelitian menunjukkan bahwa kombinasi ESP32, sensor MPU6050, *Pulse* Sensor, dan algoritma KNN efektif mendukung sistem klasifikasi aktivitas manusia berbasis IoT secara *real-time*.**

Kata Kunci*—*ESP32, internet of things, k-nearest neighbor, klasifikasi aktivitas manusia, MQTT, wearable sensor.

I. PENDAHULUAN

Perkembangan *Internet of Things* (IoT) telah mendorong pemanfaatan perangkat yang dapat dipakai sebagai pengawasan aktivitas manusia secara otomatis. Pada bidang kesehatan dan olahraga, penggabungan sensor dengan jaringan internet memungkinkan proses pengawasan kondisi fisik dilakukan secara langsung tanpa dibatasi lokasi [1]. salah satu penerapanya yaitu dengan penggunaan sensor gerak dan sensor fisiologis yang terhubung ke sistem IoT untuk memperoleh data aktivitas pengguna secara terus-menerus sehingga dapat dimanfaatkan sebagai dasar analisis kondisi fisik maupun kesehatan pengguna [2].

Berbagai penelitihan sebelumnya telah mengembangkan sistem pengenalan aktivitas manusia menggunakan data *accelerometer* dan *gyroscope* dengan algoritma *K-Nearest Neighbor* karena mampu memberikan peforma klasifikasi yang baik terhadap aktivitas Duduk, Berjalan, dan juga Berlari [3], [4].

Pada penelitian yang lain menunujukan bahwa KNN mencapai akurasi tinggi terhadap klasifikasi aktivitas manusia menggunakan data sensor*wearable*, akan tetapi sebagian besar penelitian masih berfokus pada proses klasifikasi dan belum mengintegrasikan sistem IoT maupun pemantauan kondisi fisiologis pengguna secara *real-time* [5]. Selain itu, penelitian mengenai protokol komunikasi IoT menunujukan MQTT memiliki latensi rendah dan juga penggunaan *bandwith* yang lebih efisien dibanding HTTP ataupun HTTPS sehingga sesuai untuk komunikasi data sensor secara langsung [6].

Meskipun demikian, masih terdapat kebutuhan terhadap sistem yang dapat dipakai berbasis *Internet of Things* (IoT) yang mampu melakukan proses pengambilan data secara terbuka menggunakan perangkat dengan biaya rendah, sekaligus menggabungkan informasi gerakan tubuh dan detak jantung dalam satu sistem. Sebagian besar perangkat komersial masih bersifat tertutup, sehingga data mentah sensor tidak dapat diakses secara langsung untuk kebutuhan pengembangan maupun evaluasi algoritma pembelajaran mesin. Kondisi tersebut menjadi kendala dalam pembentukan dataset dan pengembangan model pengenalan aktivitas manusia [2], [7].

Berdasarkan permasalahan tersebut, penelitian ini membuat sistem klasifikasi aktivitas manusia berbasis *Internet of Things* menggunakan mikrokontroler ESP32 dan juga sensor yang dipakai yaitu ada sensor MPU6050 dan *Pulse* Sensor. ESP32 berfungsi sebagai alat pengambilan dan pengiriman data sensor melalui protokol MQTT, sedangkan proses pengo-lahan data, pembelajaran model, dan pengujian algoritma *K-Nearest Neighbor* (KNN) dilakukan pada server menggunakan Python Notebook. Fitur yang dipakai meliputi *accel_stddev, gyro_stddev*, dan *bpm_filled* yang diperoleh melalui metode *sliding window*. Penelitian ini bertujuan membangun sis-tem pengenalan aktivitas duduk, berjalan, dan berlari serta mengevaluasi kinerja model menggunakan metrik akurasi, presisi, *recall, f1-score*, dan tabel perbandingan hasil prediksi dengan data sebenarnya [8]

II. KAJIAN TEORI

A. Internet of Things

Internet of Things (IoT) merupakan konsep yang menghubungkan berbagai perangkat fisik melalui jaringan internet sehingga mampu melakukan proses pengumpulan, pertukaran, dan pengolahan data secara otomatis [2]. Dalam sistem IoT, perangkat yang dilengkapi sensor dapat mengirimkan informasi secara langsung ke server untuk dianalisis lebih lanjut. Pada penelitian ini, IoT digunakan sebagai media komunikasi antara perangkat yang dapat dipakai berbasis ESP32 dengan server melalui protokol MQTT sehingga proses pengiriman data sensor dapat dilakukan secara terus-menerus [9].

B. Mikrokontroler ESP32 dan Sensor Wearable

Mikrokontroler ESP32 memiliki konektivitas *Wi-Fi* terintegrasi maka banyak digunakan pada sistem IoT. Pada penelidian ini, ESP32 berfungsi untuk perangkat akuisisi data yang membaca dari sensor MPU6050 dan *Pulse* Sensor, kemudian mengirimkan data tersebut ke server menggunakan protokol MQTT. Sensor MPU6050 menghasilkan data percepatan (*accelerometer*) dan kecepatan sudut (*gyroscope*), sedangkan *Pulse* Sensor digunakan untuk memperoleh nilai detak jan-tung (*Beats Per Minute*). Kombinasi ketiga perangkat tersebut memungkinkan sistem memperoleh informasi gerakan tubuh dan kondisi fisiologis pengguna secara bersamaan [10], [11].

C. Algoritma K-Nearest Neighbor

K-Nearest Neighbor (KNN) merupakan algoritma klasifikasi berbasis kemiripan data yang menentukan kelas suatu data berdasarkan sejumlah tetangga terdekat menggunakan metrik jarak, seperti *Euclidean Distance*. Algoritma ini memiliki implementasi yang sederhana, tidak memerlukan proses pembentukan model yang kompleks, serta mampu memberikan performa yang baik pada data numerik hasil sensor. Pada penelitian ini, algoritma KNN digunakan untuk mengenali aktivitas duduk, berjalan, dan berlari berdasarkan tiga ciri utama, yaitu *accel_stddev, gyro_stddev,* dan *bpm_filled*. Penentuan nilai K terbaik dilakukan menggunakan metode *5-Fold Stratified Cross Validation* sebelum proses evaluasi model [12].

III. METODE

A. Prosedur Penelitian

Penelitian dilakukan melalui beberapa tahapan yang dimulai dari studi literatur, perancangan sistem, pengambilan data sensor, *preprocessing*, pelatihan model *K-Nearest Neighbor* (KNN), samapi evaluasi model. *Flowchart* alur penelitian dapat dilihat pada Gambar 1.

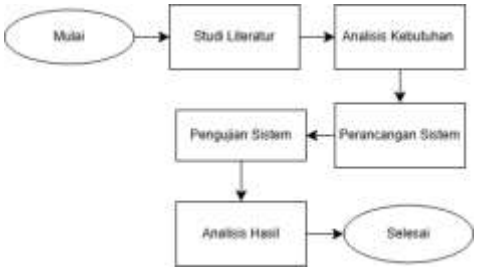

GAMBAR 1
(FLOWCHART ALUR PENELITIAN)

B. Perancangan Sistem

Sistem yang dikembangkan terdiri atas perangkat *wearable* berbasis ESP32 yang terhubung dengan sensor MPU6050 dan *Pulse* Sensor. Sensor MPU6050 menghasilkan data percepatan dan kecepatan sudut, sedangkan *Pulse* Sensor menghasilkan data BPM. ESP32 melakukan akuisisi data dengan frekuensi 50 Hz, kemudian mengirimkan data ke server melalui broker MQTT menggunakan jaringan Wi-Fi. Program *Python* menerima data sensor, melakukan pelabelan aktivitas secara manual, menyimpan dataset, melakukan *preprocessing*, melatih model KNN, kemudian mengirimkan hasil klasifikasi sehingga dapat ditampilkan melalui *dashboard web* maupun OLED.



GAMBAR 2
(DIAGRAM ARSITEKTUR SISTEM)

C. Sumber Data dan Akuisisi Data

Sumber data diperoleh melalui pengambilan data secara langsung menggunakan perangkat yang dapat dipakai yang dikenakan oleh 15 partisipan. Setiap partisipan melakukan tiga aktivitas, yaitu duduk, berjalan, dan berlari sesuai ske-nario pengambilan data. Selama proses pengambilan, ESP32 membaca data sensor MPU6050 dan *Pulse* Sensor, kemudian mengirimkannya melalui MQTT ke server. Program Python digunakan untuk memasukkan identitas partisipan, menentukan aktivitas yang dilakukan, serta memberikan label aktivitas secara manual sebelum data disimpan sebagai dataset penelitian. Dataset yang dihasilkan terdiri atas nilai *acceleromter, gyroscope*, dan bpm yang selanjutnya digunakan pada proses pembelajaran model.

D. Preprocessing Dataset

Tahap *preprocessing* dilakukan guna meningkatkan kuali-tas data sebelum digunakan pada proses klasifikasi. Proses tersebut meliputi tahap validasi dataset, imputasi nilai bpm

bernilai 0 dengan menggunakan *median* berdasarkan kelas aktivitas, penghapusan *outlier* menggunakan metode *Z-Score* dengan ambang batas ±3,5, dan juga normalisasi menggunakan *MinMaxScaler*. Setelah proses tersebut dilaukan diperoleh tiga fitur utama yaitu *accel_stddev, gyro_stddev*, dan *bpm_filled* sebagai tahap algoritma KNN, *flowchart preprocessing* dapat dilihat pada Gambar 3.



GAMBAR 3
(FLOWCHART PREPROCESSING)

E. Klasifikasi Menggunakan K-Nearest Neighbor

Model klasifikasi dibangun menggunakan algoritma K-Nearest Neighbor (KNN). Dataset dibagi menjadi data latih sebesar 80% dan data uji sebesar 20% menggunakan *Stratified Split* guna menjaga proporsi setiap kelas. Selanjutnya dilakukan mencari nilai K terbaik menggunakan metode *5-Fold Stratified Cross Validation* dengan rentang nilai K antara 1 hingga 20. Nilai K dengan rata-rata akurasi tertinggi digunakan sebagai parameter model akhir.

Perhitungan jarak antar data pada algoritma KNN menggunakan *Euclidean Distance* yang dirumuskan sebagai berikut.

$$d(x, y) = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2} \quad (1)$$

dengan:

- $d(x, y)$ = jarak Euclidean antara data uji dan data latih.
- x_i = nilai fitur ke-i pada data uji.
- y_i = nilai fitur ke-i pada data latih.
- n = jumlah fitur yang digunakan.

Persamaan 1 digunakan untuk menghitung tingkat kemiripan antara data uji dengan seluruh data latih sehingga kelas aktivitas ditentukan berdasarkan tetangga terdekat (*nearest neighbors*).

F. Evaluasi Model

Evaluasi model dilakukan menggunakan metode *confusion matrix* untuk membandingkan hasil prediksi dengan kelas sebenarnya. Selanjutnya dihitung nilai *accuracy, precision, recall*, dan *F1-score* sebagai indikator performa model dalam mengenali aktivitas duduk, berjalan, dan berlari. Selain evaluasi model, dilakukan pula pengujian sistem secara *real-time* guna memastikan proses akuisisi data, komunikasi MQTT, serta klasifikasi aktivitas berjalan sesuai rancangan sistem.

IV. HASIL DAN PEMBAHASAN

Penelitian ini berhasil membuat sistem klasifikasi aktivitas manusia berbasis *Internet of Things* menggunakan mikrokontroler ESP32, sensor MPU6050 dan *Pulse* Sensor. Sistem dapat melakukan akuisisi data aktivitas secara *real-time*, mengirim data menggunakan protokol *Message Queuing Telemetry Transport* (MQTT) membentuk dataset aktivitas, serta melakukan klasifikasi menggunakan algoritma *K-Nearest Neighbor* (KNN).

A. Hasil Pengambilan Data

Proses pengambilan data dilakukan menggunakan perangkat *wearable* yang dikenakan oleh 15 partisipan. Setiap partisipan melakukan tiga aktivitas, yaitu duduk, berjalan, dan berlari, dengan durasi perekaman 5, 10, atau 15 menit. Selama proses tersebut ESP32 membaca data *accelerometer, gyroscope*, dan bpm dengan frekuensi 50 Hz, kemudian mengirimkan data secara *real-time* ke server melalui protokol MQTT. Program *Python* menerima data tersebut, memberikan label aktivitas secara manual, dan menyimpannya ke dalam dataset penelitian.

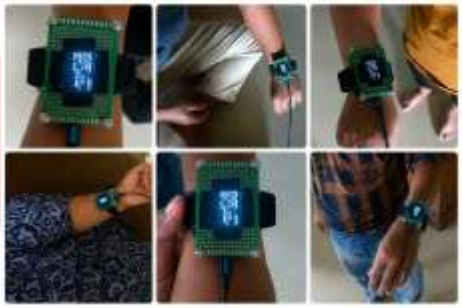

GAMBAR 4
(PROSES PENGAMBILAN DATA MENGGUNAKAN PERANGKAT WEARABLE BERBASIS ESP32)

Setelah seluruh proses pengambilan data selesai dilakukan maka diperoleh sebanyak 13.410 sampel dengan distribusi aktivitas yang relatif seimbang dan ditunjukkan pada Tabel I

TABLE I
(DISTRIBUSI DATASET AKTIVITAS)

Aktivitas	Jumlah Sampel	Persentase
Duduk	4.445	33,15%
Berjalan	4.464	33,29%
Berlari	4.501	33,56%
Total	**13.410**	**100%**

B. Hasil Preprocessing Dataset

Tahap *preprocessing* dilakukan guna meningkatkan kualitas dataset sebelum proses pelatihan model. Berdasarkan hasil analisis tidak ditemukan *missing value* pada seluruh atribut dataset. Namun, terdapat 942 sampel dengan nilai BPM sama dengan 0 sehingga dilakukan imputasi menggunakan *median* berdasarkan masing-masing kelas aktivitas. Selanjutnya dilakukan penghapusan *outlier* menggunakan metode *Z-Score* dengan ambang ±3,5 serta normalisasi menggunakan *MinMaxScaler*. Setelah proses tersebut jumlah dataset berubah dari 13.410 menjadi 13.214 sampel.

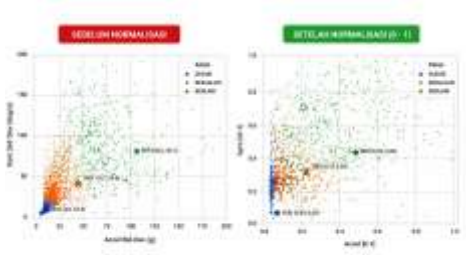

GAMBAR 5
(GRAFIK SEBELUM DAN SESUDAH NORMALISASI)

Tahap preprocessing menghasilkan dataset yang lebih bersih dan memiliki rentang nilai yang seragam sehingga lebih sesuai digunakan sebagai masukan algoritma KNN.

C. Hasil Pelatihan Model KNN

Model klasifikasi dibangun menggunakan algoritma *K-Nearest Neighbor* (KNN). Dataset dibagi menjadi 80% data latih dan 20% data uji menggunakan *Stratified Split* agar proporsi setiap kelas tetap terjaga. Selanjutnya dilakukan pencarian nilai K terbaik menggunakan metode *5-Fold Stratified Cross Validation* dengan rentang nilai K antara 1 sampai 20. Berdasarkan hasil pengujian diperoleh K = 18 sebagai parameter terbaik untuk membangun model klasifikasi.

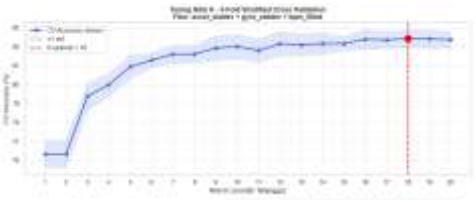

GAMBAR 6
(GRAFIK TUNING NILAI K (CV ACCURACY VD NILAI K))

Nilai K sebesar 18 dipilih karena menghasilkan rata-rata akurasi tertinggi dibandingkan nilai K lainnya sehingga digunakan pada proses pembentukan model akhir.

D. Hasil Evaluasi Model

Evaluasi model dilakukan menggunakan *confusion matrix* guna mengetahui kemampuan model dalam mengenali tiga aktivitas yang diuji.

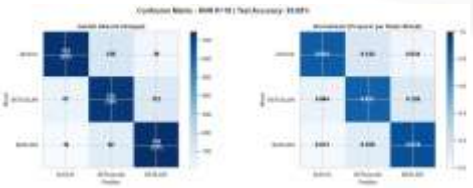

GAMBAR 7
(CONFUSION MATRIX)

Sebagian besar sampel berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi masih ditemukan pada beberapa data aktivitas duduk dan berjalan karena memiliki karakteristik pola gerakan yang relatif mirip dibandingkan aktivitas berlari.

Selain *Confusion Matrix*, dilakukan pengukuran menggunakan metrik *accuracy, precision, recall*, dan *F1-score* sebagaimana ditunjukkan pada Tabel II

TABLE II
(HASIL EVALUASI MODEL KNN)

Parameter	Nilai
Nilai K Optimal	18
Akurasi	83,69%
Precision	84,06%
Recall	83,69%
F1-Score	83,81%

Setiap kelas menunjukkan nilai *F1-Score* sebesar 78,89% untuk aktivitas duduk, 85,85% untuk aktivitas berjalan, dan 86,68% untuk aktivitas berlari. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan aktivitas dengan intensitas gerakan yang berbeda.

E. Pembahasan

Hasil penelitian menunjukkan bahwa penggabungan sensor MPU6050 dan *Pulse* Sensor mampu menghasilkan informasi gerakan dan detak jantung yang saling melengkapi dalam proses pengenalan aktivitas manusia. Fitur *accel_stddev, gyro_stddev*, dan *bpm_filled* memberikan gambaran yang baik terhadap karakteristik setiap aktivitas sehingga algoritma KNN mampu menghasilkan akurasi pengujian sebesar 83,69%. Nilai tersebut menunjukkan bahwa metode yang diusulkan mampu mengenali aktivitas duduk, berjalan, dan berlari dengan performa yang baik pada sistem yang dapat dipakai berbasis IoT. Penggunaan protokol MQTT juga memberikan komunikasi data yang stabil antara perangkat ESP32 dan server sehingga proses pengambilan secara langsung. Selain itu, pembagian proses komputasi antara perangkat IoT dan server membuat ESP32 hanya berfokus pada pengambilan dan pengiriman data, sedangkan proses pengolahan data, pembelajaran model, dan pengenalan dilakukan pada server. Pendekatan ini mengu-rangi beban komputasi pada perangkat yang dapat dipakai dan memudahkan proses pengembangan model pengenalan. Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Aktivitas yang dikenali hanya mencakup duduk, berjalan, dan berlari, serta jumlah partisipan masih terbatas pada 15 orang. Penelitian selanjutnya dapat menambahkan variasi aktivitas, memperbanyak jumlah partisipan, serta membandingkan performa KNN dengan algoritma lain seperti *Random Forest, Support Vector Machine* (SVM), maupun *Deep Learning* sehingga diperoleh model pengenalan yang lebih akurat dan lebih adaptif terhadap berbagai kondisi aktivitas manusia.

V. KESIMPULAN

Penelitian ini berhasil membuat sistem klasifikasi aktivitas manusia berbasis *Internet of Things* (IoT) menggunakan mikrokontroler ESP32, sensor MPU6050, dan *Pulse* Sensor untuk mengenali aktivitas duduk, berjalan, dan berlari. Sistem yang dikembangkan mampu melakukan akuisisi data sensor secara *real-time*, mengirimkan data melalui protokol *Message Queuing Telemetry Transport* (MQTT), serta membentuk

dataset aktivitas yang selanjutnya diproses menggunakan tahapan *preprocessing* dan algoritma *K-Nearest Neighbor* (KNN). Berdasarkan hasil pengujian, model klasifikasi memperoleh nilai K optimal sebesar 18 dengan akurasi 83,69%, *precision* 84,06%, *recall* 83,69%, dan *F1-score* 83,81%, yang menunjukkan bahwa metode yang diusulkan mampu mengenali aktivitas manusia dengan performa yang baik. Integrasi fitur *accel_stddev, gyro_stddev*, dan *bpm_filled* memberikan representasi yang efektif terhadap karakteristik setiap aktivitas sehingga mampu meningkatkan kemampuan model dalam proses klasifikasi. Selain itu, penggunaan arsitektur berbasis MQTT memungkinkan komunikasi data antara perangkat wearable dan server berlangsung secara stabil sehingga mendukung proses pemantauan aktivitas secara *real-time*. Hasil penelitian ini menunjukkan bahwa kombinasi teknologi IoT dan algoritma KNN dapat menjadi solusi yang efektif untuk pengembangan sistem pemantauan aktivitas manusia berbasis perangkat *wearable* serta dapat dijadikan dasar bagi penelitian selanjutnya dengan menambahkan variasi aktivitas, jumlah partisipan, maupun penggunaan algoritma klasifikasi yang lebih kompleks.

REFERENCES

[1] T. Tanwir, A. Asfahani, J. W. Sitopu, F. Irawan, and I. Adhicandra, "Latest Innovations in Internet of Things (IoT): Digital Transformation Across Industries," 2024, doi: 10.31004/innovative.v4i3.10551.

[2] V. Mahalakshmi, P. Kumar, M. Bhende, I. Keshta, S. Y. Rathod, and J. V. N. Ramesh, "IoT Based Wearable Sensor System Architecture for Classifying Human Activity," *Measurement: Sensors*, vol. 39, 2025, doi: 10.1016/j.measen.2025.101871.

[3] A. Belfiore, C. Cuccurullo, and M. Aria, "IoT in Healthcare: A Scientometric Analysis," *Technological Forecasting and Social Change*, vol. 184, 2022, doi: 10.1016/j.techfore.2022.122001.

[4] S. Zhang, Y. Li, S. Zhang, F. Shahabi, S. Xia, Y. Deng, and N. Al-shurafa, "Deep Learning in Human Activity Recognition with Wearable Sensors: A Review on Advances," *Sensors*, vol. 22, no. 4, 2022, doi: 10.3390/s22041476.

[5] S. Mohsen, A. Elkaseer, and S. G. Scholz, "Human Activity Recogni-tion Using K-Nearest Neighbor Machine Learning Algorithm," *Smart Innovation, Systems and Technologies*, vol. 262, pp. 304–313, 2022,

[6] S. Hong, J. Kang, and S. Kwon, "Performance Comparison of HTTP, HTTPS, and MQTT for IoT Applications," *International Journal of Advanced Smart Convergence*, vol. 12, no. 1, pp. 9–17, 2023, doi: 10.7236/IJASC.2023.12.1.9.

[7] S. D. P. O. Mutia Mawardah, "Dampak Penggunaan Teknologi Wearable terhadap Gaya Hidup dan Perilaku Kesehatan Mahasiswa di Universitas Bina Darma," *Jurnal Ilmiah PSYCHE*, 2025, doi: 10.33557/3qvecg20.

[8] Dhanush, Jangam Rani, M. Asha, "Real-Time Human Fall Detection and Alert System Using Autonomous Embedded Neural Network," *International Journal of Innovative Science and Research Technology*, 2025, doi: 10.38124/ijisrt/25sep394

[9] Zein, Liza Azzahra Basri, Mhd., "Sistem Monitoring dan Pendukung Keputusan Kondisi Kesehatan Pasien Menggunakan Integrasi Sensor Tanda Vital Berbasis IoT dengan Metode C4.5," *Hello World Jurnal Ilmu Komputer*, 2025, doi: 10.56211/helloworld.v4i3.1170

[10] Chourse, Muskan Meshram, Akshita Sharma, Ashi Kumar, Arun, "Smart Highway Safety Project with IoT and Collision Avoidance," *Peer Reviewed, Refereed, Scholarly Indexed, Open Access Journal) Impact*, 2025, doi: 10.15680/IJIRSET.2025.1406082

[11] Ryan Prayogi, Muhammad, "Journal of Artificial Intelligence and Engineering Applications Design and Development of Air Mouse Using ESP32 and MPU6050 Sensor," 2025, doi: 10.59934/jaiea.v4i3.983

[12] Liandana, Made Hostiadi, Dandy Pramana Pradipta, Gede Angga, "A New Approach for Human Activity Recognition (HAR) Using A Single Tri-axial Accelerometer Based on a Combination of Three Feature Subsets," *International Journal of Intelligent Engineering and Systems*, 2025, doi: 10.22266/ijies2024.0430.21