



Penerapan Deep Learning untuk Pengenalan Aktivitas Manusia Secara Non-Intrusif Menggunakan Wi-Fi Channel State Information

Reza Pahlevi^{1*}, Ervin Yohannes²

¹⁻²Teknik Informatika, Universitas Negeri Surabaya, Indonesia

Email: reza.22054@mhs.unesa.ac.id^{1*}, ervinyohannes@unesa.ac.id²

*Penulis Korespondensi : reza.22054@mhs.unesa.ac.id

Abstract. This study is motivated by the increasing need for accurate modeling and classification of one-dimensional signal data in intelligent systems. The rapid development of deep learning has led to the adoption of more adaptive and complex neural network architectures capable of capturing both temporal dependencies and local patterns in sequential data. This research aims to analyze and compare the performance of several deep learning models, namely Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and a hybrid Convolutional Neural Network–GRU (CNN–GRU) model for signal data classification. The research method employs a quantitative experimental approach involving data preprocessing, windowing, model training, and performance evaluation. Model performance is evaluated using accuracy, precision, recall, and F1-score metrics. The results indicate that the hybrid CNN–GRU model outperforms the other models, particularly in capturing local features and long-term temporal dependencies within signal data. These findings suggest that the integration of convolutional layers and recurrent mechanisms enhances feature representation and learning stability. This study is expected to contribute both theoretically and practically to the development of deep learning models for signal processing and time-series-based intelligent applications.

Keywords: CNN-GRU; Deep Learning; Neural Network; Signal Classification; Time Series.

Abstrak. Penelitian ini dilatarbelakangi oleh meningkatnya kebutuhan akan pemodelan dan klasifikasi data sinyal satu dimensi yang akurat dalam sistem cerdas. Perkembangan pesat teknologi deep learning mendorong penggunaan arsitektur jaringan saraf yang semakin adaptif dan kompleks dalam menangkap ketergantungan temporal serta pola lokal pada data berurutan. Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja beberapa model deep learning, yaitu Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), serta model hibrida Convolutional Neural Network–GRU (CNN–GRU) dalam melakukan klasifikasi data sinyal. Metode penelitian menggunakan pendekatan eksperimen kuantitatif yang meliputi tahap prapemrosesan data, pembentukan window, pelatihan model, dan evaluasi kinerja. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model hibrida CNN–GRU memiliki performa paling unggul dibandingkan model lainnya, terutama dalam mengekstraksi fitur lokal dan memodelkan dependensi temporal jangka panjang. Temuan ini mengindikasikan bahwa integrasi CNN dan GRU mampu meningkatkan kemampuan representasi fitur serta stabilitas pembelajaran model. Penelitian ini diharapkan dapat memberikan kontribusi teoretis dan praktis dalam pengembangan model deep learning untuk pengolahan data sinyal dan aplikasi sistem cerdas berbasis deret waktu.

Kata kunci: CNN-GRU; Deret Waktu; Jaringan Saraf Tiruan; Klasifikasi Sinyal; Pembelajaran Mendalam.

1. LATAR BELAKANG

Seiring dengan pesatnya adopsi teknologi Internet of Things (IoT) yang diperkirakan akan terus bertumbuh secara global, lingkungan cerdas (smart environment) menjadi semakin terintegrasi dalam kehidupan sehari-hari (Shafiqul Islam et al., 2024). Salah satu kapabilitas utama dari lingkungan cerdas adalah kemampuannya untuk mengenali aktivitas manusia atau Human Activity Recognition (HAR) secara otomatis (Zhuravchak et al., 2022). Sistem HAR memiliki potensi aplikasi yang krusial, terutama pada sektor keselamatan dan keamanan, seperti mendeteksi kondisi darurat medis atau mengenali keberadaan penyusup. Oleh karena

itu, pengembangan sistem HAR yang andal menjadi area penelitian yang sangat relevan dan aktif, menarik perhatian besar dari komunitas akademis maupun industri (Shi et al., 2022).

Pendekatan yang paling umum untuk HAR adalah menggunakan sistem berbasis visi seperti kamera. Namun, metode ini memiliki dua kelemahan fundamental, yaitu biaya perangkat keras yang tinggi dan isu pelanggaran privasi pengguna yang signifikan (Chahoushi et al., 2023). Tantangan ini mendorong peneliti untuk mencari solusi alternatif yang bersifat non-intrusif. Salah satu terobosan teknologi yang menjanjikan adalah pemanfaatan sinyal Wi-Fi, yang infrastrukturnya sudah ada di mana-mana. Metode ini bekerja dengan menganalisis data Channel State Information (CSI), yaitu informasi detail mengenai kondisi kanal yang berubah akibat pergerakan manusia. Meskipun menjanjikan, pendekatan berbasis Wi-Fi CSI juga memiliki tantangan tersendiri, seperti sensitivitas terhadap noise lingkungan dan ketergantungan performa model pada lokasi spesifik (Al-Qaness et al., 2019).

Data CSI menawarkan informasi yang jauh lebih kaya dan detail dibandingkan metrik kekuatan sinyal (Received Signal Strength Indicator/RSSI), sehingga memungkinkan pengenalan pola aktivitas dengan lebih akurat (Chen et al., 2025). Untuk menerjemahkan data sinyal CSI yang kompleks dan penuh noise menjadi klasifikasi aktivitas, pendekatan Deep Learning terbukti sangat efektif. Berbagai arsitektur deep learning telah dieksplorasi untuk tugas ini. Beberapa penelitian mengusulkan model hibrida seperti CNN-GRU untuk mengekstrak fitur spasial dan temporal secara bersamaan (Quy et al., 2025). Penelitian lain berfokus pada pengembangan model yang ringan dan efisien, misalnya dengan menambahkan mekanisme atensi pada arsitektur GRU untuk mengurangi ukuran model dan biaya komputasi secara signifikan.

Meskipun banyak model telah diusulkan, beberapa tantangan fundamental masih menjadi area riset yang sangat aktif. Salah satu tantangan terbesar adalah independensi lokasi (location independence), di mana kemampuan model untuk bekerja secara andal di lingkungan yang berbeda dari tempat data pelatihan dikumpulkan masih sangat terbatas (Abuhoureyah et al., 2025). Masalah ini menjadi fokus penting untuk meningkatkan kepraktisan sistem HAR di dunia nyata (Ding et al., 2021). Di luar Wi-Fi, sinyal frekuensi radio (RF) secara umum juga telah berhasil digunakan untuk HAR dengan model seperti Temporal Convolutional Network (TCN) (Varga, 2024) dan model hibrida LSTM-Random Forest (Gorji et al., 2021), yang menunjukkan luasnya potensi teknologi penginderaan berbasis sinyal.

Meninjau penelitian acuan oleh Zhuravchak et al. yang berhasil menerapkan model LSTM pada dataset CSI yang mereka kumpulkan dalam skenario realistis, penelitian ini mengidentifikasi celah penelitian yang penting. Meskipun LSTM terbukti efektif, arsitektur

tersebut memiliki kompleksitas komputasi yang lebih tinggi. Oleh karena itu, penelitian ini bertujuan untuk melakukan investigasi empiris terhadap arsitektur Gated Recurrent Unit (GRU), LSTM, RNN, dan model hybrid CNN-GRU yang secara teoretis lebih efisien, dengan mengujinya pada dataset publik yang sama. Dengan demikian, penelitian ini akan memberikan perbandingan kinerja yang adil dan langsung antara keempat model tersebut pada benchmark yang telah tervalidasi.

2. KAJIAN TEORITIS

Human Activity Recognition (HAR) adalah sebuah bidang penelitian dalam ilmu komputer dan kecerdasan buatan yang berfokus pada pengembangan sistem untuk secara otomatis mendeteksi, mengklasifikasikan, dan memahami aktivitas yang dilakukan oleh manusia berdasarkan data yang dikumpulkan dari berbagai sensor (Alsaify et al., 2022). Tujuan utama dari HAR adalah untuk menjembatani kesenjangan antara data sensor mentah dan pemahaman kontekstual tingkat tinggi mengenai perilaku manusia, yang memungkinkan interaksi yang lebih cerdas dan proaktif antara manusia dan teknologi.

Pentingnya HAR telah berkembang pesat seiring dengan kemajuan teknologi sensor dan Internet of Things (IoT). Aplikasinya sangat luas dan mencakup berbagai domain krusial. Dalam sektor kesehatan, HAR digunakan untuk pemantauan pasien jarak jauh, deteksi jatuh pada lansia, dan analisis pola tidur untuk diagnosis medis. Di lingkungan rumah pintar (smart home), sistem HAR dapat mengotomatiskan pencahayaan, suhu, dan sistem keamanan berdasarkan aktivitas penghuni, sehingga meningkatkan kenyamanan dan efisiensi energi (Oleh et al., 2024). Selain itu, dalam bidang keamanan dan pengawasan, HAR berperan penting dalam mendeteksi perilaku mencurigakan atau abnormal secara otomatis (Hiremath & Plötz, 2023).

Data deret waktu atau time series adalah serangkaian titik data yang diurutkan secara kronologis, di mana setiap titik data direkam pada interval waktu yang berurutan. Karakteristik paling fundamental dari data deret waktu adalah adanya dependensi temporal, yang berarti nilai observasi pada satu titik waktu memiliki hubungan atau ketergantungan dengan nilai-nilai pada titik waktu sebelumnya. Sifat sekuensial ini membedakan data deret waktu dari data transaksional biasa, di mana urutan data tidak memiliki makna intrinsik.

Dalam konteks Human Activity Recognition (HAR), data yang dihasilkan oleh sensor, termasuk sinyal Wi-Fi CSI, pada dasarnya adalah data deret waktu. Ketika seseorang melakukan sebuah aktivitas, gerakan tubuhnya menyebabkan fluktuasi pada amplitudo dan fasa sinyal CSI yang diterima. Fluktuasi ini direkam secara terus-menerus dari waktu ke waktu,

menghasilkan sebuah sekuens data yang mengandung pola-pola dinamis yang unik untuk setiap jenis aktivitas (Serpush et al., 2022). Oleh karena itu, tugas untuk mengenali aktivitas manusia dari sinyal CSI dapat dipandang sebagai masalah klasifikasi data deret waktu (time series classification).

Pemodelan data deret waktu memiliki tantangan tersendiri. Model klasifikasi machine learning tradisional sering kali mengasumsikan bahwa setiap sampel data bersifat independen dan tidak memiliki hubungan satu sama lain (independent and identically distributed). Asumsi ini tidak berlaku untuk data deret waktu, di mana urutan data sangat penting. Mengabaikan dependensi temporal akan menghilangkan informasi kontekstual yang krusial untuk memahami aktivitas yang sedang berlangsung.

Untuk mengatasi tantangan ini, pendekatan yang umum digunakan adalah dengan teknik jendela geser (sliding window). Teknik ini membagi data deret waktu yang kontinu menjadi segmen-segmen yang lebih kecil dan sering kali tumpang tindih (overlapping). Setiap segmen atau "jendela" ini kemudian dianggap sebagai satu sampel data sekuensial yang akan dimasukkan ke dalam model.

Karena sifat data yang sekuensial ini, diperlukan arsitektur model yang secara eksplisit dirancang untuk memproses urutan, seperti Recurrent Neural Networks (RNN). Model RNN dan variannya, seperti GRU dan LSTM, memiliki mekanisme memori internal yang memungkinkan mereka untuk mempertahankan informasi dari langkah waktu sebelumnya saat memproses langkah waktu saat ini. Kemampuan untuk menangkap pola temporal inilah yang membuat model-model tersebut sangat efektif untuk tugas-tugas klasifikasi data deret waktu seperti HAR.

Dalam sistem komunikasi nirkabel modern, sinyal yang ditransmisikan dari pengirim (Tx) ke penerima (Rx) merambat melalui berbagai jalur akibat pantulan, pembiasan, dan penghamburan oleh objek-objek di lingkungan sekitar. Fenomena ini dikenal sebagai multipath propagation (rambatan multijalur). Channel State Information (CSI) adalah metrik pada lapisan fisik (physical layer) yang memberikan informasi terperinci mengenai kondisi atau properti dari kanal komunikasi ini. Secara esensial, CSI mendeskripsikan bagaimana sinyal Wi-Fi terpengaruh baik dari segi pelemahan amplitudo maupun pergeseran fasa saat merambat melalui lingkungan tersebut (Yang et al., 2023).

Prinsip dasar pemanfaatan CSI untuk Human Activity Recognition (HAR) adalah bahwa setiap gerakan manusia, sekecil apa pun, akan menyebabkan gangguan atau perubahan pada jalur rambatan sinyal Wi-Fi. Perubahan ini menciptakan pola fluktuasi yang unik pada data CSI yang diterima (Mosleh et al., 2022). Dengan menganalisis pola-pola dinamis ini dari

waktu ke waktu, sistem dapat "merasakan" dan mengklasifikasikan berbagai jenis aktivitas manusia secara pasif, tanpa memerlukan sensor yang terpasang di tubuh atau kamera yang melanggar privasi.

Data Channel State Information (CSI) mentah yang diekstraksi dari perangkat Wi-Fi secara inheren mengandung berbagai macam distorsi, seperti noise acak, outlier (data pencilan), dan ketidakstabilan fasa. Distorsi ini dapat berasal dari interferensi lingkungan, ketidaksempurnaan perangkat keras, atau pergerakan yang tidak terkait dengan aktivitas yang diamati (Bocus et al., 2022). Oleh karena itu, tahap pra-pemrosesan data menjadi langkah fundamental dan krusial untuk membersihkan dan menstabilkan sinyal CSI, sehingga fitur-fitur yang relevan dengan aktivitas manusia dapat diekstraksi secara efektif oleh model deep learning. Tanpa pra-pemrosesan yang tepat, performa dan keandalan sistem HAR dapat menurun secara signifikan (Zarzycki & Ławryńczuk, 2021).

Penelitian ini akan menerapkan serangkaian teknik pra-pemrosesan yang telah terbukti efektif dalam berbagai studi HAR berbasis CSI, yang mencakup sanitasi fasa, penghapusan outlier menggunakan Hampel Identifier, dan reduksi noise menggunakan Discrete Wavelet Transform (DWT).

Data Channel State Information (CSI) mentah yang diekstraksi dari perangkat Wi-Fi secara inheren mengandung berbagai macam distorsi, seperti noise acak, outlier (data pencilan), dan ketidakstabilan fasa. Distorsi ini dapat berasal dari interferensi lingkungan, ketidaksempurnaan perangkat keras, atau pergerakan yang tidak terkait dengan aktivitas yang diamati. Oleh karena itu, tahap pra-pemrosesan data menjadi langkah fundamental dan krusial untuk membersihkan dan menstabilkan sinyal CSI, sehingga fitur-fitur yang relevan dengan aktivitas manusia dapat diekstraksi secara efektif oleh model deep learning. Tanpa pra-pemrosesan yang tepat, performa dan keandalan sistem HAR dapat menurun secara signifikan. Sanitasi Fasa (Phase Sanitization)

Informasi fasa dalam data CSI mentah sangat sensitif terhadap perubahan lingkungan, namun sayangnya tidak dapat digunakan secara langsung. Hal ini disebabkan oleh adanya pergeseran fasa acak yang disebabkan oleh ketidaksinkronan antara pengirim dan penerima, yang dikenal sebagai Carrier Frequency Offset (CFO) dan Sampling Frequency Offset (SFO). Pergeseran ini mengaburkan informasi fasa yang sebenarnya, yang seharusnya berkorelasi dengan pergerakan manusia.

Untuk mengatasi masalah ini, diperlukan proses sanitasi fasa. Salah satu pendekatan yang umum digunakan adalah menerapkan transformasi linear pada data fasa mentah untuk mengoreksi pergeseran acak tersebut. Tujuannya adalah untuk menghilangkan komponen

offset yang tidak relevan dan menghasilkan data fasa yang telah "dibersihkan" atau dikalibrasi (Zhou et al., 2023). Dengan melakukan sanitasi, informasi fasa yang stabil dan bermakna dapat diekstraksi, yang kemudian dapat digabungkan dengan informasi amplitudo untuk memberikan representasi sinyal yang lebih kaya dan akurat bagi model.

Deep Learning adalah cabang dari machine learning yang menggunakan Jaringan Saraf Tiruan (Artificial Neural Networks) dengan banyak lapisan (arsitektur dalam atau deep) untuk secara otomatis mempelajari representasi data yang kompleks. Berbeda dengan metode machine learning tradisional yang sering kali memerlukan rekayasa fitur (feature engineering) secara manual, model deep learning mampu mengekstraksi fitur-fitur relevan secara hierarkis langsung dari data mentah (Gupta et al., 2022). Kemampuan ini menjadikan deep learning sangat efektif untuk menangani data yang kompleks dan berdimensi tinggi seperti sinyal Wi-Fi CSI, yang secara inheren mengandung banyak noise dan pola yang sulit diinterpretasikan secara manual.

Untuk mengukur dan memvalidasi kinerja model deep learning yang diusulkan dalam tugas klasifikasi aktivitas manusia, diperlukan serangkaian metrik evaluasi yang objektif dan standar. Evaluasi ini merupakan tahap krusial untuk mengetahui sejauh mana model mampu membedakan antara berbagai kelas aktivitas dengan akurat. Model yang ideal adalah model yang dapat menghasilkan prediksi dengan tingkat kesalahan seminimal mungkin. Dalam penelitian ini, performa model GRU akan dianalisis menggunakan confusion matrix serta metrik turunan darinya, yaitu accuracy, precision, recall, dan F1-score (Shi & Juanatas, 2025).

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengevaluasi kinerja beberapa arsitektur deep learning dalam klasifikasi data sinyal satu dimensi. Tahapan penelitian meliputi prapemrosesan data, pembentukan window data, pelatihan model, serta evaluasi performa. Data sinyal yang digunakan terlebih dahulu melalui proses normalisasi untuk menyamakan rentang nilai dan mengurangi pengaruh perbedaan skala antar data. Selanjutnya, data dibentuk ke dalam skema windowing agar dapat merepresentasikan dependensi temporal pada setiap segmen sinyal. Dataset kemudian dibagi menjadi data latih dan data uji dengan proporsi yang konsisten untuk seluruh skenario pengujian.

Model yang digunakan dalam penelitian ini meliputi Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), serta model hibrida Convolutional Neural Network-GRU (CNN-GRU). Seluruh model dilatih menggunakan

konfigurasi hyperparameter yang sama, yaitu batch size 128, learning rate 0,001, jumlah epoch 150, optimizer Adam, serta fungsi loss kategorikal. Penyeragaman konfigurasi ini dilakukan untuk memastikan perbandingan kinerja yang adil. Evaluasi kinerja model dilakukan menggunakan beberapa metrik, yaitu akurasi, presisi, recall, dan F1-score. Hasil evaluasi selanjutnya dianalisis secara komparatif untuk mengidentifikasi model dengan performa paling optimal dalam klasifikasi data sinyal.

4. HASIL DAN PEMBAHASAN

Hasil

Penelitian ini bertujuan untuk membandingkan kinerja beberapa arsitektur deep learning dalam melakukan klasifikasi data sinyal satu dimensi. Model yang diuji meliputi Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), serta model hibrida Convolutional Neural Network–GRU (CNN–GRU). Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Berikut ini tabel hasil evaluasi yang dihasilkan setiap model dengan skenario split data terbaik:

Tabel 1. Hasil Evaluasi Model Pada Skenario terbaik.

Model	Akurasi Test	Precision	Recall	F1-Score
RNN	97,58%	0,9762	0,9758	0,9759
LSTM	99,48%	0,9948	0,9948	0,9948
GRU	99,60%	0,9960	0,9960	0,9960
CNN-GRU	99,68%	0,9968	0,9968	0,9968

Hasil eksperimen menunjukkan bahwa terdapat perbedaan performa yang cukup signifikan antar model. Model RNN konvensional menghasilkan performa paling rendah, terutama pada metrik akurasi dan F1-score. Hal ini mengindikasikan bahwa RNN memiliki keterbatasan dalam mempelajari dependensi jangka panjang pada data sinyal yang bersifat kompleks.

Model LSTM dan GRU menunjukkan peningkatan performa yang lebih stabil dibandingkan RNN. Mekanisme gerbang yang dimiliki kedua model tersebut memungkinkan pengelolaan aliran informasi yang lebih efektif, sehingga mampu menangkap dependensi temporal dengan lebih baik. Meskipun demikian, performa LSTM dan GRU masih berada di bawah model hibrida CNN–GRU.

Model CNN–GRU menghasilkan performa terbaik secara keseluruhan. Integrasi lapisan konvolusi memungkinkan model mengekstraksi fitur lokal yang lebih representatif dari data sinyal, sedangkan lapisan GRU berperan dalam memodelkan hubungan temporal antar fitur tersebut.

Akurasi Model

Hasil pengujian menunjukkan bahwa model CNN–GRU memiliki nilai akurasi tertinggi dibandingkan model lainnya. Peningkatan akurasi ini menunjukkan bahwa model mampu melakukan klasifikasi data sinyal dengan tingkat kesalahan yang lebih rendah. Sebaliknya, model RNN menghasilkan akurasi terendah, yang mengindikasikan keterbatasan dalam mengenali pola kompleks pada data berurutan.

Precision dan Recall

Evaluasi precision dan recall dilakukan untuk menilai kemampuan model dalam mengklasifikasikan setiap kelas secara proporsional. Model CNN–GRU menunjukkan keseimbangan presisi dan recall yang lebih baik dibandingkan model lain. Hal ini menandakan bahwa model tidak hanya mampu memberikan prediksi yang tepat, tetapi juga mampu mengenali sebagian besar data dari setiap kelas secara konsisten.

F1-Score

F1-score digunakan sebagai metrik gabungan untuk mengevaluasi keseimbangan antara presisi dan recall. Berdasarkan hasil pengujian, model CNN–GRU memiliki nilai F1-score tertinggi, yang menunjukkan stabilitas kinerja yang lebih baik. Nilai F1-score yang lebih rendah pada model RNN menunjukkan bahwa model tersebut kurang optimal dalam menangani variasi pola pada data sinyal.

Pembahasan

Hasil penelitian ini menunjukkan bahwa model hibrida CNN–GRU memiliki keunggulan dibandingkan model RNN, LSTM, dan GRU dalam klasifikasi data sinyal satu dimensi. Keunggulan tersebut berasal dari kemampuan CNN dalam mengekstraksi fitur lokal yang relevan, seperti pola amplitudo dan perubahan sinyal, serta kemampuan GRU dalam memodelkan dependensi temporal jangka panjang.

Kombinasi kedua arsitektur tersebut menghasilkan representasi fitur yang lebih kaya dan informatif, sehingga meningkatkan performa klasifikasi secara keseluruhan. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa model hibrida cenderung lebih efektif dibandingkan model tunggal dalam menangani data deret waktu yang kompleks.

Dengan demikian, penggunaan model CNN–GRU dapat menjadi solusi yang efektif untuk meningkatkan kinerja sistem klasifikasi data sinyal berbasis pembelajaran mendalam,

khususnya pada aplikasi yang memerlukan pemrosesan data berurutan dengan karakteristik nonlinier.

5. KESIMPULAN DAN SARAN

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja beberapa arsitektur deep learning, yaitu Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), serta model hibrida Convolutional Neural Network–Gated Recurrent Unit (CNN–GRU) dalam klasifikasi data sinyal berbasis Wi-Fi Channel State Information (CSI). Berdasarkan hasil eksperimen dan analisis yang telah dilakukan, dapat disimpulkan bahwa terdapat perbedaan performa yang signifikan di antara keempat model tersebut.

Model RNN konvensional menunjukkan performa paling rendah, terutama dalam mempelajari dependensi temporal jangka panjang pada data sinyal yang kompleks. Model LSTM dan GRU mampu memberikan peningkatan performa yang lebih stabil dibandingkan RNN, berkat mekanisme gerbang yang memungkinkan pengelolaan aliran informasi secara lebih efektif. Namun demikian, kedua model tersebut masih memiliki keterbatasan dalam mengekstraksi pola lokal yang bersifat spasial pada data CSI.

Model hibrida CNN–GRU menghasilkan performa terbaik secara keseluruhan, yang ditunjukkan oleh nilai akurasi, presisi, recall, dan F1-score yang lebih tinggi dan konsisten dibandingkan model lainnya. Integrasi lapisan konvolusi pada CNN memungkinkan ekstraksi fitur lokal yang representatif dari data sinyal, sementara GRU berperan dalam memodelkan dependensi temporal antar fitur tersebut. Temuan ini menunjukkan bahwa pendekatan hibrida lebih efektif dalam menangani karakteristik data CSI yang bersifat berdimensi tinggi, berurutan, dan mengandung noise lingkungan.

Berdasarkan hasil penelitian ini, dapat disarankan agar penelitian selanjutnya mengeksplorasi variasi arsitektur hibrida lainnya, seperti penambahan mekanisme attention atau penggabungan dengan model berbasis transformer, guna meningkatkan kemampuan generalisasi model. Selain itu, pengujian pada skenario lingkungan yang lebih beragam dan bersifat location-independent juga perlu dilakukan untuk meningkatkan keandalan model dalam penerapan dunia nyata. Penelitian lanjutan juga disarankan untuk mengkaji efisiensi komputasi dan kompleksitas model agar sistem pengenalan aktivitas berbasis CSI dapat diimplementasikan secara optimal pada perangkat dengan sumber daya terbatas.

DAFTAR REFERENSI

- Abuhoureyah, F., Wong, Y. C., Al-Taweel, M. H., & Abdullah, N. I. (2025). Challenges and opportunities to location independent human activity recognition utilizing Wi-Fi sensing. *International Journal of Electrical and Computer Engineering (IJECE)*, 15(1), 921. <https://doi.org/10.11591/ijece.v15i1.pp921-939>
- Al-qaness, M. A. A., Abd Elaziz, M., Kim, S., Ewees, A. A., Abbasi, A. A., Alhaj, Y. A., & Hawbani, A. (2019). Channel state information from pure communication to sense and track human motion: A survey. *Sensors*, 19(15), 3329. <https://doi.org/10.3390/s19153329>
- Alsaify, B. A., Almazari, M. M., Alazrai, R., Alouneh, S., & Daoud, M. I. (2022). A CSI-based multi-environment human activity recognition framework. *Applied Sciences*, 12(2), 930. <https://doi.org/10.3390/app12020930>
- Bocus, M. J., Li, W., Vishwakarma, S., Kou, R., Tang, C., Woodbridge, K., Craddock, I., McConville, R., Santos-Rodriguez, R., Chetty, K., & Piechocki, R. (2022). OPERAnet, a multimodal activity recognition dataset acquired from radio frequency and vision-based sensors. *Scientific Data*, 9(1), 474. <https://doi.org/10.1038/s41597-022-01573-2>
- Chahoushi, M., Nabati, M., Asvadi, R., & Ghorashi, S. A. (2023). CSI-based human activity recognition using multi-input multi-output autoencoder and fine-tuning. *Sensors*, 23(7), 3591. <https://doi.org/10.3390/s23073591>
- Chen, X., Li, C., Jiang, C., Meng, W., & Xiao, W. (2025). WiPhase: A human activity recognition approach by fusing of reconstructed Wi-Fi CSI phase features. *IEEE Transactions on Mobile Computing*, 24(1), 394–406. <https://doi.org/10.1109/TMC.2024.3461672>
- Ding, X., Jiang, T., Zhong, Y., Huang, Y., & Li, Z. (2021). Wi-Fi-based location-independent human activity recognition via meta learning. *Sensors*, 21(8), 2654. <https://doi.org/10.3390/s21082654>
- Gorji, A., Gielen, T., Bauduin, M., Sahli, H., & Bourdoux, A. (2021). A multi-radar architecture for human activity recognition in indoor kitchen environments. *2021 IEEE Radar Conference (RadarConf21)*, 1–6. <https://doi.org/10.1109/RadarConf2147009.2021.9455238>
- Gupta, N., Gupta, S. K., Pathak, R. K., Jain, V., Rashidi, P., & Suri, J. S. (2022). Human activity recognition in artificial intelligence framework: A narrative review. *Artificial Intelligence Review*, 55(6), 4755–4808. <https://doi.org/10.1007/s10462-021-10116-x>
- Hiremath, S. K., & Plötz, T. (2023). The lifespan of human activity recognition systems for smart homes. *Sensors*, 23(18), 7729. <https://doi.org/10.3390/s23187729>
- Mosleh, S., Coder, J. B., Scully, C. G., Forsyth, K., & Kalaa, M. O. A. (2022). Monitoring respiratory motion with Wi-Fi CSI: Characterizing performance and the BreatheSmart algorithm. *IEEE Access*, 10, 131932–131951. <https://doi.org/10.1109/ACCESS.2022.3230003>
- Oleh, U., Obermaisser, R., & Ahammed, A. S. (2024). A review of recent techniques for human activity recognition: Multimodality, reinforcement learning, and language models. *Algorithms*, 17(10), 434. <https://doi.org/10.3390/a17100434>

- Quay, T. D., Lin, C.-Y., & Shih, T. K. (2025). Enhanced human activity recognition using Wi-Fi sensing: Leveraging phase and amplitude with attention mechanisms. *Sensors*, 25(4), 1038. <https://doi.org/10.3390/s25041038>
- Serpush, F., Menhaj, M. B., Masoumi, B., & Karasfi, B. (2022). Wearable sensor-based human activity recognition in the smart healthcare system. *Computational Intelligence and Neuroscience*, 2022, 1–31. <https://doi.org/10.1155/2022/1391906>
- Shafiqul Islam, Md., Humayun Kabir, M., Ali Hasan, Md., & Shin, W. (2024). Wi-MIR: A CSI dataset for Wi-Fi based multi-person interaction recognition. *IEEE Access*, 12, 67256–67272. <https://doi.org/10.1109/ACCESS.2024.3395173>
- Shi, W., & Juanatas, R. A. (2025). Emotion-aware gate controllers: Dynamically weighted GRU architectures with sentiment polarity guidance-EI. <https://doi.org/10.2139/ssrn.5205521>
- Shi, Z., Cheng, Q., Zhang, J. A., & Yi Da Xu, R. (2022). Environment-robust Wi-Fi-based human activity recognition using enhanced CSI and deep learning. *IEEE Internet of Things Journal*, 9(24), 24643–24654. <https://doi.org/10.1109/JIOT.2022.3192973>
- Varga, D. (2024). Mitigating data leakage in a Wi-Fi CSI benchmark for human action recognition. *Sensors*, 24(24), 8201. <https://doi.org/10.3390/s24248201>
- Yang, M., Zhu, H., Zhu, R., Wu, F., Yin, L., & Yang, Y. (2023). WiTransformer: A novel robust gesture recognition sensing model with Wi-Fi. *Sensors*, 23(5), 2612. <https://doi.org/10.3390/s23052612>
- Zarzycki, K., & Ławryńczuk, M. (2021). LSTM and GRU neural networks as models of dynamical processes used in predictive control: A comparison of models developed for two chemical reactors. *Sensors*, 21(16), 5625. <https://doi.org/10.3390/s21165625>
- Zhou, H., Zhang, Y., & Temiz, M. (2023). High-resolution indoor sensing using channel state information of Wi-Fi networks. *Electronics*, 12(18), 3931. <https://doi.org/10.3390/electronics12183931>
- Zhuravchak, A., Kapshii, O., & Pournaras, E. (2022). Human activity recognition based on Wi-Fi CSI data - A deep neural network approach. *Procedia Computer Science*, 198, 59–66. <https://doi.org/10.1016/j.procs.2021.12.211>