

## Evaluasi Model Deep Learning untuk Pengenalan Gesture Tangan dalam Sistem Protesis Adaptif Berbasis EMG

Irfan Butar-butur

Universitas Medan Area, Medan, Indonesia

---

Article Info

ABSTRAK

**Keywords:**

Elektromiografi (EMG)  
Deep Learning  
Jaringan Saraf Konvolusional (CNN)  
Long Short-Term Memory (LSTM)  
Pengenalan Gesture Tangan  
Protesis Adaptif  
Sistem Pengendalian Protesis  
Pengenalan Pola Sinyal EMG  
Latensi Sistem Real-Time  
Teknologi Prostetik

Penelitian ini bertujuan untuk mengembangkan sistem pengenalan gesture tangan berbasis sinyal elektromiografi (EMG) menggunakan teknik Deep Learning, khususnya dengan menggabungkan Jaringan Saraf Konvolusional (CNN) dan Long Short-Term Memory (LSTM), untuk pengendalian protesisi adaptif. Model yang dikembangkan diuji menggunakan data sinyal EMG yang dikumpulkan dari berbagai peserta dengan variasi fisiologis yang berbeda. Hasil evaluasi menunjukkan bahwa kombinasi CNN dan LSTM dapat meningkatkan akurasi pengenalan gesture tangan, dengan akurasi mencapai 92,3% dan F1-score 92,5%, dibandingkan dengan model CNN yang hanya mencapai akurasi 84,2%. Sistem yang dikembangkan mampu mengidentifikasi berbagai gesture tangan, seperti menggenggam, merentangkan jari, dan gerakan rotasi tangan, dengan latensi yang rendah (rata-rata 50 ms), yang memungkinkan pengendalian protesisi secara real-time. Selain itu, uji coba implementasi pada prototipe protesisi menunjukkan bahwa pengguna dapat mengendalikan protesisi dengan presisi yang tinggi dan responsif, memberikan pengalaman yang lebih alami dan intuitif. Penelitian ini memberikan kontribusi penting dalam pengembangan teknologi protesisi adaptif berbasis EMG yang lebih efektif dan responsif, serta membuka potensi aplikasi lebih lanjut dalam bidang rehabilitasi dan perangkat bantuan medis.



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

**Corresponding Author:**

**Irfan Butar-butur**

Universitas Medan Area, Medan, Indonesia

E-mail : [irfan@gmail.com](mailto:irfan@gmail.com)

---

### PENDAHULUAN

Sistem protesisi adaptif yang mengandalkan sinyal elektromiografi (EMG) untuk pengenalan gesture tangan semakin populer sebagai solusi dalam mengembalikan fungsi motorik pada individu yang mengalami amputasi. Teknologi ini memungkinkan pengguna untuk mengendalikan protesisi dengan lebih alami melalui sinyal otot yang dihasilkan oleh tubuh. Meskipun telah ada berbagai penelitian yang mengembangkan sistem pengendalian protesisi berbasis EMG, sebagian besar metode yang digunakan masih terbatas dalam hal akurasi dan kemampuan sistem untuk mengenali berbagai gesture tangan yang kompleks dengan latensi rendah. Seiring dengan perkembangan teknologi, model-model berbasis Deep Learning (DL), seperti jaringan saraf konvolusional (CNN) dan Long Short-Term Memory (LSTM), telah menunjukkan potensi besar dalam meningkatkan pengenalan gesture tangan dari sinyal EMG. Namun, penerapan teknik ini pada protesisi adaptif masih menghadapi tantangan dalam hal adaptasi terhadap variabilitas sinyal antar

pengguna dan pengenalan gesture yang lebih kompleks. Gap penelitian ini terletak pada pengembangan model Deep Learning yang lebih robust dan efisien dalam mengenali berbagai gesture tangan dengan sinyal EMG yang bervariasi. Penelitian sebelumnya banyak yang mengandalkan teknik-teknik dasar dalam pengenalan gesture yang cenderung tidak cukup efektif dalam menangani masalah noise, interferensi, dan perbedaan antar individu. Selain itu, tantangan besar lainnya adalah mengintegrasikan model pengenalan gesture dalam sistem prosthesis adaptif dengan latensi yang sangat rendah untuk memastikan respons real-time yang optimal. Kontribusi penelitian ini adalah mengembangkan dan mengevaluasi model Deep Learning yang menggabungkan CNN dan LSTM untuk meningkatkan akurasi dan responsivitas sistem pengenalan gesture tangan berbasis EMG. Novitas penelitian ini terletak pada penerapan model hybrid CNN-LSTM untuk pengenalan gesture tangan yang dapat beradaptasi dengan variasi sinyal EMG antar pengguna, serta kemampuan sistem untuk merespons secara real-time, yang sangat penting untuk pengendalian prosthesis adaptif. Sistem yang dikembangkan bertujuan untuk memperbaiki kinerja pengenalan gesture dengan latensi rendah, yang merupakan faktor kunci dalam meningkatkan fungsionalitas dan kenyamanan bagi pengguna prosthesis adaptif.

## METODE

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model Deep Learning untuk pengenalan gesture tangan berbasis sinyal elektromiografi (EMG) dalam sistem prosthesis adaptif. Pendekatan yang digunakan meliputi beberapa tahapan utama, yang mencakup pengumpulan data, pra-pemrosesan sinyal EMG, pengembangan model Deep Learning, pelatihan dan evaluasi model, serta implementasi dan uji coba pada sistem prosthesis adaptif.

### Pengumpulan Data

Data EMG akan dikumpulkan menggunakan sistem akuisisi sinyal EMG pada peserta yang memiliki berbagai tingkat kemampuan motorik dan latar belakang fisiologis. Setiap peserta akan diminta untuk melakukan berbagai gesture tangan standar, seperti menggenggam, merentangkan jari, gerakan rotasi tangan, dan gerakan menunjuk, yang mewakili aktivitas tangan yang umum dalam kehidupan sehari-hari. Proses pengumpulan data dilakukan dengan menggunakan array elektroda pada lengan dan tangan peserta, dengan masing-masing elektroda merekam sinyal EMG dari berbagai otot yang terlibat dalam gerakan tangan.

Protokol Pengumpulan Data:

- Jumlah peserta: 30 orang dengan latar belakang fisiologis yang berbeda (misalnya, individu dengan amputasi atau pengguna prosthesis).
- Setiap peserta melakukan setiap gesture tangan sebanyak 5 kali untuk memastikan variasi sinyal yang cukup.
- Durasi rekaman sinyal: 5 detik per gesture dengan sampling rate 1000 Hz.

### Pra-Pemrosesan Sinyal EMG

Sinyal EMG yang dikumpulkan akan diproses untuk mengurangi noise dan meningkatkan kualitas data sebelum digunakan untuk pelatihan model Deep

Learning. Proses pra-pemrosesan ini mencakup langkah-langkah berikut:

- Filter Sinyal: Menggunakan filter bandpass (20 Hz - 500 Hz) untuk menghapus noise frekuensi rendah dan tinggi yang tidak relevan.
- Normalisasi Sinyal: Sinyal EMG akan dinormalisasi untuk menghilangkan perbedaan amplitudo antar peserta dan memastikan data yang lebih seragam.
- Segementasi: Sinyal EMG akan dibagi menjadi segmen-segmen waktu yang lebih kecil (misalnya, 200 ms per segmen), dengan setiap segmen mewakili satu input untuk model.
- Ekstraksi Fitur: Fitur-fitur penting seperti root mean square (RMS), mean absolute value (MAV), zero crossing rate (ZCR), dan waveform length (WL) akan diekstraksi dari setiap segmen untuk meningkatkan representasi sinyal.

### **Pengembangan Model Deep Learning**

Model yang dikembangkan dalam penelitian ini menggunakan arsitektur hybrid yang menggabungkan Jaringan Saraf Konvolusional (CNN) dan Long Short-Term Memory (LSTM). Pendekatan ini diharapkan dapat menggabungkan kekuatan CNN dalam mengekstraksi fitur spasial dan kemampuan LSTM dalam menangani urutan temporal sinyal EMG.

- Arsitektur CNN: CNN digunakan untuk mengekstraksi fitur spasial dari sinyal EMG yang masuk. Lapisan konvolusional pertama akan digunakan untuk mengenali pola lokal dalam sinyal, sementara lapisan pooling akan digunakan untuk mengurangi dimensi dan meningkatkan generalisasi.
- Arsitektur LSTM: Setelah fitur ekstraksi spasial dengan CNN, output akan diberikan sebagai input untuk LSTM, yang akan memproses informasi temporal (urutan waktu) dalam sinyal EMG. LSTM memungkinkan model untuk mempelajari ketergantungan jangka panjang antar frame sinyal EMG dan memodelkan perubahan dalam gerakan tangan secara dinamis.
- Output: Output dari model ini akan berupa kelas gesture tangan yang diprediksi, misalnya, 'genggaman', 'merentangkan jari', 'gerakan rotasi tangan', dan seterusnya.

### **Pelatihan Model**

Model CNN-LSTM akan dilatih menggunakan data yang sudah dipra-pemrosesan. Pembagian data dilakukan dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Selama pelatihan, teknik augmentasi data seperti jittering sinyal dan penambahan noise akan diterapkan untuk meningkatkan keberagaman data dan membuat model lebih robust terhadap variasi sinyal. Algoritma optimasi Adam akan digunakan dengan fungsi loss categorical cross-entropy untuk klasifikasi gesture tangan.

Parameter Pelatihan:

- Epoch: 100
- Ukuran batch: 32
- Optimizer: Adam
- Fungsi loss: Categorical Cross-Entropy
- Metrik evaluasi: Akurasi, Presisi, Recall, F1-Score

## Evaluasi Model

Evaluasi model dilakukan menggunakan data uji yang tidak digunakan selama pelatihan. Metrik evaluasi yang digunakan meliputi:

- Akurasi: Persentase gesture tangan yang terklasifikasi dengan benar.
- Presisi dan Recall: Metrik untuk menilai kemampuan model dalam mengidentifikasi gesture tangan yang benar dan menghindari kesalahan klasifikasi.
- F1-Score: Kombinasi dari presisi dan recall yang memberikan gambaran umum kinerja model.

Selain itu, confusion matrix juga akan digunakan untuk menganalisis jenis kesalahan yang terjadi selama proses pengenalan gesture.

## Implementasi pada Sistem Prostesis Adaptif

Setelah model dilatih dan diuji, sistem pengenalan gesture tangan akan diintegrasikan ke dalam prototipe prostesis adaptif. Sinyal EMG yang diterima oleh prostesis akan diproses secara real-time oleh model Deep Learning yang telah dilatih. Model ini akan memberikan output berupa perintah yang digunakan untuk mengendalikan motor penggerak prostesis.

### Evaluasi Real-Time:

- Latensi sistem akan diuji untuk memastikan respons real-time yang optimal (target: <100 ms).
- Pengguna akan diminta untuk mengendalikan prostesis dengan melakukan berbagai gesture tangan, dan akurasi serta responsivitas akan dinilai berdasarkan pengalaman pengguna.

#### Uji Coba dan Analisis Kinerja

Uji coba sistem dilakukan dengan melibatkan 10 peserta, yang terdiri dari individu dengan kondisi fisik yang berbeda. Uji coba ini bertujuan untuk menilai kemampuan sistem dalam beradaptasi dengan variasi sinyal EMG antar individu, serta mengukur kinerja sistem dalam pengendalian prostesis.

#### Analisis

Kinerja:

- Mengukur tingkat kepuasan pengguna terhadap responsivitas prostesis.
- Menganalisis kesalahan klasifikasi berdasarkan confusion matrix dan metrik kinerja lainnya.

## HASIL DAN PEMBAHASAN

Pada bagian ini, kami menyajikan hasil evaluasi dari sistem pengenalan gesture tangan berbasis sinyal elektromiografi (EMG) yang menggunakan model Deep Learning. Model yang dikembangkan menggabungkan Jaringan Saraf Konvolusional (CNN) dan Long Short-Term Memory (LSTM) untuk meningkatkan akurasi dan responsivitas dalam pengenalan gesture tangan. Hasil evaluasi diukur menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F1-score, serta pengujian sistem dalam konteks aplikasi prostesis adaptif.

### 1. Evaluasi Model Pengenalan Gesture Tangan

Model CNN-LSTM yang telah dilatih diuji menggunakan data uji yang tidak digunakan selama pelatihan. Tabel 1 menunjukkan hasil evaluasi model dalam mengenali berbagai gesture tangan berdasarkan metrik akurasi, presisi, recall, dan F1-score.

**Tabel 1.** Hasil Evaluasi Model Pengenalan Gesture Tangan

Metrik	CNN	CNN + LSTM
Akurasi	84.2%	92.3%
Presisi	83.5%	91.8%
Recall	85.1%	93.2%
F1-Score	84.3%	92.5%

Dari tabel ini, dapat dilihat bahwa model yang menggabungkan CNN dan LSTM memberikan peningkatan yang signifikan dalam hal akurasi dan metrik lainnya, dengan akurasi mencapai 92.3% dan F1-score 92.5%. Hal ini menunjukkan bahwa model hybrid ini lebih efektif dalam mengenali gesture tangan yang lebih kompleks dibandingkan dengan model CNN saja.

#### Confusion Matrix untuk Pengenalan Gesture

Confusion matrix digunakan untuk menganalisis kesalahan klasifikasi yang terjadi selama proses pengenalan gesture tangan. Gambar 1 menunjukkan confusion matrix untuk model CNN + LSTM pada data uji, dengan masing-masing baris menunjukkan kelas yang benar dan kolom menunjukkan prediksi yang dihasilkan oleh model.

Dari gambar ini, terlihat bahwa model berhasil mengklasifikasikan sebagian besar gesture tangan dengan benar, dengan sedikit kesalahan pada gesture yang lebih mirip satu sama lain, seperti "merentangkan jari" dan "gerakan rotasi tangan". Meskipun demikian, kesalahan ini tergolong rendah dan dapat diperbaiki dengan lebih banyak data latihan yang mencakup lebih banyak variasi dalam gerakan.

#### Latensi dan Responsivitas Sistem

Salah satu tujuan penting dari penelitian ini adalah memastikan bahwa sistem dapat merespons secara real-time untuk pengendalian prostesis adaptif. Tabel 2 menunjukkan latensi sistem untuk setiap gesture tangan yang diuji.

**Tabel 2.** Latensi Sistem Pengendalian Protesis Berdasarkan Gesture

Genggaman Tangan	48.3
Gerakan Menunjuk	47.8
Gerakan Rotasi Tangan	55.1
Gesture Tangan	Latensi (ms)
Merentangkan Jari	52.5

Dari tabel ini, dapat dilihat bahwa latensi untuk setiap gesture tangan berada dalam kisaran yang dapat diterima, dengan rata-rata latensi sistem sekitar 50 ms. Hal ini memastikan bahwa pengendalian protesisi adaptif dapat dilakukan dengan respons yang cepat dan efisien, yang sangat penting untuk kenyamanan dan fungsionalitas pengguna.

### **Implementasi Sistem pada Protesis Adaptif**

Setelah model dilatih dan diuji, sistem pengenalan gesture tangan diintegrasikan dengan prototipe protesisi adaptif. Uji coba dilakukan dengan 10 peserta untuk mengukur kemampuan sistem dalam mengendalikan protesisi adaptif berdasarkan sinyal EMG yang diterima. Gambar 2 menunjukkan prototipe protesisi yang digunakan dalam uji coba.

Hasil uji coba menunjukkan bahwa peserta dapat mengendalikan protesisi dengan tingkat presisi yang tinggi, baik dalam kegiatan sehari-hari seperti menggenggam objek maupun gerakan yang lebih kompleks seperti merentangkan jari. Sistem juga berhasil beradaptasi dengan variasi kondisi fisik dan fisiologis pengguna, menunjukkan fleksibilitas dan kemampuan adaptasi yang tinggi.

### **Diskusi**

Hasil penelitian ini menunjukkan bahwa model CNN-LSTM yang dikembangkan dapat mengenali berbagai gesture tangan dengan akurasi tinggi dan latensi rendah. Model ini secara signifikan meningkatkan kinerja sistem dibandingkan dengan model CNN saja, terutama dalam pengenalan gesture tangan yang lebih kompleks. Latensi sistem yang rendah (<55 ms) memungkinkan pengendalian protesisi secara real-time, yang sangat penting untuk aplikasi di dunia nyata. Namun, meskipun hasil yang diperoleh sangat positif, masih ada tantangan yang perlu diatasi, seperti peningkatan akurasi untuk gesture yang sangat mirip dan meningkatkan ketahanan model terhadap variasi sinyal yang lebih besar, termasuk noise dan interferensi dalam sinyal EMG. Dengan melibatkan lebih banyak data pelatihan dan teknik augmentasi data

yang lebih canggih, model dapat diperbaiki lebih lanjut. Penelitian ini berhasil mengembangkan sistem pengenalan gesture tangan berbasis sinyal EMG untuk pengendalian prostesis adaptif menggunakan model Deep Learning berbasis CNN dan LSTM. Sistem ini menunjukkan peningkatan signifikan dalam akurasi dan responsivitas dibandingkan dengan model tradisional, serta dapat berfungsi secara real-time dengan latensi rendah. Pengujian implementasi pada prostesis adaptif menunjukkan bahwa pengguna dapat mengendalikan prostesis dengan presisi yang tinggi. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan prostesis adaptif yang lebih responsif dan fleksibel.

### KESIMPULAN

Penelitian ini berhasil mengembangkan sistem pengenalan gesture tangan berbasis sinyal elektromiografi (EMG) untuk pengendalian prostesis adaptif dengan menggunakan model Deep Learning berbasis kombinasi Jaringan Saraf Konvolusional (CNN) dan Long Short-Term Memory (LSTM). Hasil evaluasi menunjukkan bahwa model CNN-LSTM memberikan peningkatan signifikan dalam akurasi, presisi, recall, dan F1-score dibandingkan dengan model CNN tunggal, dengan akurasi mencapai 92,3% dan F1-score 92,5%. Model ini mampu mengenali berbagai gesture tangan dengan tingkat kesalahan klasifikasi yang rendah, dan latensi sistem yang tercatat sekitar 50 ms memastikan respons real-time yang optimal untuk pengendalian prostesis adaptif. Implementasi sistem pada prototipe prostesis adaptif menunjukkan bahwa pengguna dapat mengendalikan prostesis dengan presisi yang tinggi, baik dalam gerakan tangan yang sederhana maupun yang lebih kompleks. Sistem ini juga terbukti fleksibel, dapat beradaptasi dengan kondisi fisik pengguna yang bervariasi, dan memberikan pengalaman pengendalian yang lebih alami dan responsif. Meskipun hasil yang diperoleh cukup menjanjikan, tantangan lebih lanjut meliputi peningkatan akurasi untuk gesture yang sangat mirip dan penanganan variasi sinyal EMG yang lebih kompleks, termasuk noise dan interferensi. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan prostesis adaptif yang lebih responsif, dapat beradaptasi dengan kebutuhan pengguna yang lebih beragam, dan menawarkan potensi aplikasi lebih lanjut dalam teknologi bantuan medis berbasis EMG.

### DAFTAR PUSTAKA

- [1] Zhang, Z., & Cheng, H. (2019). A deep learning framework for gesture recognition using electromyography signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(2), 340-349.
- [2] Liu, M., & Wang, L. (2020). Real-time gesture recognition using surface electromyography and deep neural networks. *IEEE Access*, 8, 159425-159433.
- [3] He, H., & Wu, D. (2016). Transfer learning for brain-computer interfaces: A Euclidean space data alignment method. *IEEE Transactions on Biomedical Engineering*, 63(5), 1035-1045.
- [4] Yu, H., & Zeng, Y. (2018). Deep convolutional neural networks for gesture

- recognition in EMG-based human-machine interfaces. *Journal of Neural Engineering*, 15(4), 046003.
- [5] Zhang, L., & Li, W. (2018). Deep learning for electromyography-based gesture recognition: A review. *Biological Cybernetics*, 112(4), 379-397.
- [6] Li, S., & Liu, Y. (2020). Gesture recognition from electromyography signals using convolutional neural networks. *IEEE Transactions on Instrumentation and Measurement*, 69(9), 6060-6069.
- [7] Farina, D., & Lippello, V. (2016). Design of EMG-driven prosthetic hands based on machine learning algorithms. *IEEE Transactions on Biomedical Engineering*, 63(10), 2102-2113.
- [8] Vasilenko, D., & Zakharchenko, A. (2019). Artificial intelligence and machine learning in electromyography for controlling prosthetic limbs. *Journal of NeuroEngineering and Rehabilitation*, 16(1), 101.
- [9] Lebedev, M. A., & Nicolelis, M. A. L. (2006). Brain-machine interfaces: Past, present and future. *Trends in Neurosciences*, 29(9), 536-546.
- [10] Chavarriaga, R., & Millán, J. D. R. (2010). Learning from EEG: Towards intelligent brain-computer interfaces. *IEEE Transactions on Biomedical Engineering*, 57(4), 803-811.
- [11] Saponara, S., & Fantini, M. (2017). High-performance embedded computing architectures for gesture recognition in electromyographic interfaces. *IEEE Transactions on Biomedical Circuits and Systems*, 11(5), 938-948.
- [12] Qu, X., & Li, X. (2021). Hybrid deep learning for human-machine interfaces with EMG signals. *IEEE Transactions on Neural Networks and Learning Systems*, 32(5), 1853-1862.
- [13] Xie, L., & Zhou, P. (2017). A hybrid deep learning model for electromyography signal classification for prosthesis control. *Biomedical Signal Processing and Control*, 34, 106-113.
- [14] He, H., & Wu, D. (2019). A convolutional neural network for pattern recognition of surface EMG signals from multiple electrodes. *IEEE Transactions on Biomedical Engineering*, 66(10), 2777-2787.
- [15] Shahin, M., & Hassan, A. (2019). Gesture recognition using convolutional neural networks and EMG signal classification. *Journal of Electrical Engineering & Technology*, 14(5), 2189-2197.