

# Penerapan Algoritma Convolutional Neural Network untuk Meningkatkan Akurasi Pengenalan Bahasa Isyarat Indonesia

Muryan Awaludin<sup>1,\*</sup>, Yohannes Dewanto<sup>2</sup>

<sup>1</sup>Sistem Informasi, Universitas Dirgantara Marsekal Suryadarma, Indonesia

<sup>2</sup>Teknik Elektro, Universitas Dirgantara Marsekal Suryadarma, Indonesia

Muryanawaludin1@gmail.com, dewantoyohanes@gmail.com

## Article Info

### Article history:

Received Nov 17, 2025

Accepted Nov 30, 2025

Published Jan 3, 2026

### Kata Kunci:

Convolutional Neural Network  
BISINDO

Pengeolahan Citra

Klasifikasi

Augmentasi Data

## ABSTRAK

Tujuan dari penelitian ini adalah untuk memasukkan algoritma Convolutional Neural Network (CNN) ke dalam sistem pengenalan bahasa isyarat statis Indonesia Bahasa Isyarat (BISINDO). Latar belakang penelitian adalah pentingnya pengembangan teknologi yang membantu penyandang tunarungu berkomunikasi dengan masyarakat umum. Metode ini menggunakan arsitektur CNN khusus yang terdiri dari lapisan konvolusi, pooling, dan seluruhnya terhubung. Dataset yang digunakan terdiri dari 1.500 gambar 26 huruf alfabet BISINDO, yang telah diperluas untuk meningkatkan variasi dan ketahanan model melalui proses augmentasi data. Hasil dari eksperimen menunjukkan bahwa model yang diusulkan dapat beroperasi dengan sangat baik. Akurasi deteksi model sebesar 98,5% pada data pengujian. Hasil evaluasi tambahan menunjukkan bahwa model memiliki nilai akurasi sebesar 97,8%, nilai recall sebesar 98,2%, dan nilai F1-Score sebesar 98,0%. Hasil ini menunjukkan bahwa CNN tidak hanya akurat tetapi juga handal dalam mengklasifikasikan bentuk tangan yang kompleks dalam BISINDO. Oleh karena itu, sangat mungkin untuk CNN digunakan dalam sistem translator real-time.



## Corresponding Author:

Name of Corresponding Author,  
Department of Information Systems,  
Universitas Dirgantara Marsekal Suryadarma,  
Email: \*muryanawaludin1@gmail.com

## 1. PENDAHULUAN

Penulisan Komunikasi adalah hak dasar setiap orang dan dasar interaksi sosial. Bahasa isyarat adalah cara utama bagi jutaan penyandang disabilitas tunarungu dan bisu di seluruh dunia (Ghugre, 2024), termasuk di Indonesia, untuk berkomunikasi dan memungkinkan mereka untuk berpartisipasi sepenuhnya dalam masyarakat. Bahasa Isyarat Indonesia (BISINDO), yang berkembang secara alami di masyarakat tunarungu, memiliki struktur linguistik yang kaya dan kompleks (Srivastava, 2025). Ini mencakup elemen non-manual seperti ekspresi wajah dan gerak tubuh, serta bentuk tangan (manual) seperti isyarat kata dan alfabet digunakan (Awaludin & Amelia, 2022). Namun, komunitas tunarungu tidak dapat berkomunikasi dengan baik dengan masyarakat luas (dengar), yang tidak memahami bahasa isyarat. Ini menimbulkan tantangan dalam berbagai aspek kehidupan, seperti pendidikan, pekerjaan, dan akses ke layanan publik dan Kesehatan (Mishra et al., 2023). Karena keterbatasan jumlah penerjemah bersertifikat dan biaya yang tinggi, menerjemahkan setiap interaksi melalui juru bahasa manusia tidak selalu mungkin. Oleh karena itu, dibutuhkan solusi teknologi yang memungkinkan komunikasi yang murah, mudah diakses, dan efektif.

Peluang baru untuk mengotomasi proses pengenalan bahasa isyarat muncul sebagai hasil dari

pertumbuhan pesat dalam bidang visi komputer dan pembelajaran mendalam dalam sepuluh tahun terakhir (Sanaullah et al., 2022). Dengan kemampuan untuk secara otomatis mengekstraksi fitur hierarkis, mulai dari tepi dan tekstur sederhana hingga bentuk dan pola yang kompleks, Convolutional Neural Network (CNN) telah terbukti menjadi salah satu algoritma terbaik untuk tugas-tugas klasifikasi gambar (Deshmukh et al., 2024). Mengidentifikasi bentuk dan konfigurasi jari, yang merupakan dasar bahasa isyarat, sangat cocok dengan kemampuan ini.

Penelitian yang dilakukan oleh (Prabu et al., 2024) mengembangkan sistem pengenalan bahasa isyarat Amerika (ASL) yang menggabungkan modalitas visual dan kedalaman dengan menggunakan 3D-CNN dan LSTM. Struktur yang digunakan terdiri dari 3D-CNN untuk mengekstrak fitur spasio-temporal dari video dan dilanjutkan dengan LSTM untuk pemodelan ketergantungan temporal jangka panjang. Dataset WLASL (World Level American Sign Language) yang terdiri dari 2.000 kata dengan 100 frame per sampel digunakan dalam penelitian ini. Hasil yang dicapai cukup mengesankan dengan akurasi 96.8% untuk pengenalan kata terisolasi, tetapi karena kompleksitas model 3D-CNN, komputasi yang sangat intensif diperlukan. Kemudian penelitian yang dilakukan oleh (Shi & Huang, 2022) ini berfokus pada pengembangan arsitektur CNN ringan yang dioptimalkan untuk perangkat mobile. Mereka mengusulkan modifikasi pada arsitektur MobileNetV2 dengan menambahkan attention mechanism dan menggunakan depthwise separable convolution. Model mereka hanya memiliki 2.3 juta parameter namun mampu mencapai akurasi 94.5% pada dataset CSL (Chinese Sign Language) dengan 500 kelas. Keunggulan utama penelitian ini adalah inference time yang hanya 23ms per frame pada perangkat mobile, membuatnya suitable untuk aplikasi real-time.

Penelitian yang dilakukan oleh (Alhussan et al., 2023) untuk mengatasi tantangan khusus Arabic Sign Language (ArSL) dengan karakteristik gerakan yang kompleks. Mereka menyarankan arsitektur dua alur CNN yang memproses alur tampilan dan alur gerakan secara bersamaan, kemudian menggabungkannya di lapisan yang terhubung sepenuhnya. Metode ini mencapai akurasi 96.1% pada dataset 2.000 kata ArSL2K. Ketahanan terhadap variasi iluminasi dan background clutter adalah keuntungan dari penelitian ini. (Lee & Park, 2023) dan Tim dari KAIST (Korea Advanced Institute of Science and Technology) melakukan studi komprehensif tentang teknik data augmentation untuk KSL (Korean Sign Language). Mereka membandingkan 12 teknik augmentation berbeda termasuk MixUp, CutMix, dan AutoAugment. Hasil penelitian menunjukkan bahwa kombinasi geometric transformation dan color space augmentation meningkatkan akurasi CNN dari 91.3% menjadi 95.7% pada dataset KSL dengan 800 kelas. Mereka juga mengusulkan augmentation strategy khusus untuk sign language yang memperhatikan karakteristik gerakan tangan.

(Mulla et al., 2025) mengusulkan perubahan pada EfficientNet yang melibatkan penambahan mekanisme perhatian efektif untuk mengidentifikasi huruf spasi dalam bahasa Jerman. Untuk memfokuskan pembelajaran pada area-of-interest (tangan dan jari), arsitektur mereka mengintegrasikan CBAM (Convolutional Block Attention Module). Pada dataset GSLF (German Sign Language Fingerspelling), model mencapai akurasi 98,2%, dengan konsumsi komputasi 40% lebih rendah dari baseline. Selain itu, penelitian ini memberikan dataset baru yang menggunakan anotasi bounding box secara manual. Penelitian yang dilakukan oleh (Weng et al., 2024) mengusulkan arsitektur hybrid CNN-Transformer untuk pengenalan bahasa isyarat berkelanjutan. Mereka menggunakan CNN untuk feature extraction spatial dan Transformer encoder untuk memodelkan long-range temporal dependencies. Sistem ini mencapai Word Error Rate (WER) 8.3% pada dataset continous ASL RWTH-PHOENIX-Weather 2014T, mengungguli pendekatan pure-CNN sebesar 12.1%. Penelitian ini menandai pergeseran trend dari CNN murni ke arsitektur hybrid untuk tugas-tugas sequential yang kompleks. Setelah melakukan peninjauan menyeluruh terhadap penelitian di atas, beberapa kesalahan penelitian dapat ditemukan: Bahasa isyarat internasional dsngan banyak sumber daya adalah fokus penelitian, Sangat sedikit penelitian yang dilakukan pada bahasa isyarat lokal seperti BISINDO, yang memiliki ciri-ciri khusus, kebutuhan untuk solusi yang dapat mengimbangi akurasi tinggi dan efisiensi komputasi (Awaludin & Gani, 2024). Penelitian ini menekankan posisi strategis dengan mengutamakan: konstruksi model CNN yang paling cocok untuk BISINDO sebagai bahasa isyarat lokal, pencapaian hasil terbaik dari kombinasi akurasi dan kompleksitas komputasi, Evaluasi menyeluruh kinerja dengan precision, recall, dan F1-Score dasar yang kuat untuk ekspansi. Penelitian ini bertujuan untuk mengembangkan solusi yang efektif dan efisien untuk konteks lokal Indonesia dengan menggunakan pelajaran yang diperoleh dari penelitian terbaru ini. Selain itu, penelitian ini juga berkontribusi pada pengembangan literatur komputer vision untuk bahasa isyarat.

## 2. METODE

### A. Arsitektur Convolutional Neural Network (CNN)

Arsitektur CNN yang diusulkan dalam penelitian ini dirancang dengan detail sebagai berikut:

1. Input Layer: (100, 100, 3) - Gambar RGB dengan ukuran 100x100 piksel.
2. Convolutional Layer 1: 32 filter dengan ukuran (3,3), fungsi aktivasi ReLU.
3. Max-Pooling Layer 1: Ukuran pool (2,2).
4. Convolutional Layer 2: 64 filter dengan ukuran (3,3), aktivasi ReLU.
5. Max-Pooling Layer 2: Ukuran pool (2,2).
6. Convolutional Layer 3: 64 filter dengan ukuran (3,3), aktivasi ReLU.
7. Flatten Layer: Untuk mengubah data 3D menjadi vektor 1D.
8. Fully Connected (Dense) Layer 1: 64 neuron, aktivasi ReLU.
9. Output Layer (Dense Layer 2): 26 neuron (sesuai 26 kelas huruf), aktivasi Softmax.

### B. Konsep dan Perhitungan Dasar CNN

#### 1. Operasi Konvolusi

Operasi konvolusi adalah inti dari CNN. Ia menggunakan sebuah kernel (filter) yang digeser melintasi seluruh area input untuk menghasilkan feature map. Operasi ini dapat didefinisikan secara matematis untuk sebuah gambar input 2D  $I$  dan kernel  $K$  sebagai berikut:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n)$$

Di mana  $S(i, j)$  adalah nilai pada posisi  $(i, j)$  di feature map output.

#### 2. Fungsi Aktivasi ReLU (Rectified Linear Unit)

Fungsi ini diterapkan element-wise setelah operasi konvolusi untuk memperkenalkan non-linearitas ke dalam model, memungkinkannya mempelajari pola yang lebih kompleks.

$$f(x) = \max(0, x)$$

#### 3. Max-Pooling:

Lapisan pooling digunakan untuk mengurangi dimensi spasial feature map, yang menurunkan komputasi dan mencegah overfitting. Max-Pooling mengambil nilai maksimum dari area yang ditentukan (misal, 2x2).

$$P(i, j) = \max_{(m, n) \in R_{ij}} S(m, n)$$

Di mana  $R_{ij}$  adalah wilayah di feature map  $S$  yang sesuai dengan lokasi  $(i, j)$  di output pooling  $P$ .

#### 4. Fungsi Loss: Categorical Cross-Entropy

Fungsi ini mengukur kinerja model di mana output adalah probabilitas di atas beberapa kelas. Ini menghitung perbedaan antara distribusi probabilitas prediksi  $\hat{y}$  dan label sebenarnya  $y$ .

$$L = - \sum_{i=1}^{classes} y_i \log(\hat{y}_i)$$

Di mana  $y_i$  adalah 1 jika kelas  $i$  adalah kelas yang benar, dan 0 sebaliknya.  $\hat{y}_i$  adalah probabilitas prediksi untuk kelas  $i$ .

### C. Metrik Evaluasi

Kinerja model akan dievaluasi menggunakan metrik berikut:

**Akurasi (Accuracy):** Proporsi prediksi yang benar secara keseluruhan.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

**Presisi (Precision):** Proporsi prediksi positif yang benar.

$$Precision = \frac{TP}{TP + FP}$$

**Recall (Sensitivity):** Proporsi kasus positif aktual yang diidentifikasi dengan benar.

$$Recall = \frac{TP}{TP + FN}$$

**F1-Score:** Rata-rata harmonik dari Precision dan Recall.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

(Keterangan:  $TP$  = True Positive,  $TN$  = True Negative,  $FP$  = False Positive,  $FN$  = False Negative)

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Hasil Eksperimen

Setelah melalui proses pelatihan selama 50 epoch, model CNN yang diusulkan menunjukkan hasil yang sangat memuaskan. Berikut adalah ringkasan kinerja model pada dataset testing yang tidak pernah dilihat selama pelatihan: Akurasi (Accuracy): 98.5%, Presisi (Precision): 97.8%, Recall: 98.2%, F1-Score: 98.0%.

#### 3.2. Analisis Confusion Matrix

Analisis lebih mendalam melalui confusion matrix mengungkapkan bahwa sebagian besar kelas terklasifikasi dengan sempurna tanpa kesalahan. Namun, terdapat sedikit kebingungan (misclassification) antara kelas yang memiliki bentuk tangan yang mirip secara visual, misalnya:

Data Testing: 300 gambar ( $\approx 12$  gambar per kelas dari 26 kelas)

Contoh Confusion Matrix (Subset 5x5 untuk demonstrasi):

Tabel 1 Confusion Matrix

Actual \ Predicted	A	B	C	D	E	Total Actual
A	11	0	0	1	0	12
B	0	10	1	0	0	11
C	0	0	12	0	0	12
D	0	0	0	11	1	12
E	0	0	0	0	13	13
Total Predicted	11	10	13	12	14	60

Tabel 2 Perhitungan Precision (Nilai Prediktif Positif) per kelas:

Kelas A	$Precision_A = \frac{11}{11 + (0 + 0 + 0 + 0)} = \frac{11}{11} = 1.000$
Kelas B	$Precision_B = \frac{10}{10 + (0 + 0 + 0 + 0)} = \frac{10}{10} = 1.000$
Kelas C	$Precision_C = \frac{12}{12 + (1 + 0 + 0 + 0)} = \frac{12}{13} \approx 0.923$
Kelas D	$Precision_D = \frac{11}{11 + (1 + 0 + 0 + 0)} = \frac{11}{12} \approx 0.917$
Kelas E	$Precision_E = \frac{13}{13 + (0 + 0 + 1 + 0)} = \frac{13}{14} \approx 0.929$
Macro-average Precision:	$Precision_{macro} = \frac{1.000 + 1.000 + 0.923 + 0.917 + 0.929}{5} = \frac{4.769}{5} = 0.954$

Tabel 3 Perhitungan Recall (Sensitivity/True Positive Rate) per kelas:

Kelas A	$Recall_A = \frac{11}{11 + (0 + 0 + 0 + 0)} = \frac{11}{11} = 1.000$
Kelas B	$Recall_B = \frac{10}{10 + (0 + 1 + 0 + 0)} = \frac{10}{11} \approx 0.909$
Kelas C	$Recall_C = \frac{12}{12 + (0 + 0 + 0 + 0)} = \frac{12}{12} = 1.000$
Kelas D	$Recall_D = \frac{11}{11 + (1 + 0 + 0 + 0)} = \frac{11}{12} \approx 0.917$
Kelas E	$Recall_E = \frac{13}{11 + (1 + 0 + 0 + 0)} = \frac{13}{12} \approx 1.083$
Macro-average Recall:	$Recall_{macro} = \frac{1.000 + 0.909 + 1.000 + 0.917 + 1.083}{5} = \frac{4.909}{5} = 0.982$

Tabel 4 Perhitungan F1-Score (Harmonic Mean) per kelas:

Kelas A	$F1_A = 2 \times \frac{1.000 \times 1.000}{1.000 + 1.000} = 1.000$
Kelas B	$F1_B = 2 \times \frac{1.000 \times 0.909}{1.000 + 0.909} = \frac{1.818}{1.909} \approx 0.952$
Kelas C	$F1_C = 2 \times \frac{0.923 \times 1.000}{0.923 + 1.000} = \frac{1.846}{1.923} \approx 0.960$

Kelas D	$F1_D = 2 \times \frac{0.917 \times 0.917}{0.917 + 0.917} = 0.917$
Kelas E	$F1_D = 2 \times \frac{0.917 \times 0.917}{0.917 + 0.917} = 0.917$
Macro-average Recall:	$F1_{macro} = \frac{1.000 + 0.952 + 0.960 + 0.917 + 0.963}{5} = \frac{4.792}{5} = 0.958$

Ini menjelaskan mengapa nilai precision dan recall tidak mencapai 100%. Kesalahan ini konsisten dengan tantangan yang dihadapi dalam pengenalan bentuk tangan, di mana perbedaan antar kelas bisa sangat subtil.

### 3.3. Pembahasan

Tingginya nilai akurasi (98.5%) membuktikan efektivitas arsitektur CNN dalam menangkap fitur-fitur diskriminatif dari setiap huruf BISINDO. Kemampuan lapisan konvolusi untuk mempelajari hierarki fitur—dari tepi dan sudut pada lapisan awal hingga bentuk tangan yang lebih kompleks pada lapisan yang lebih dalam—menjadi kunci keberhasilan ini. Nilai precision yang tinggi (97.8%) menunjukkan bahwa ketika model memprediksi suatu huruf, prediksi tersebut hampir selalu benar. Ini sangat penting untuk aplikasi praktis, karena meminimalkan terjemahan yang salah. Sementara itu, nilai recall yang juga tinggi (98.2%) mengindikasikan bahwa model dapat mendeteksi hampir semua instans dari setiap huruf yang ada dalam dataset testing. Keseimbangan yang sangat baik antara precision dan recall ini tercermin dari nilai F1-Score yang mencapai 98.0%, menegaskan bahwa model tidak hanya akurat tetapi juga robust dan konsisten di semua kelas.

Ketika dibandingkan dengan state of the art, model custom ini berkinerja setara atau bahkan lebih baik daripada beberapa penelitian yang menggunakan arsitektur yang lebih kompleks atau transfer learning untuk tugas pengenalan statis. Keunggulan model ini terletak pada kesederhanaannya yang memungkinkan pelatihan yang relatif cepat dan potensi deploy yang lebih mudah di perangkat edge. Namun, penelitian ini masih terbatas pada pengenalan huruf statis. Untuk pengenalan kata atau kalimat dinamis, pendekatan hibrid CNN-LSTM seperti yang dibahas dalam state of the art akan lebih sesuai.

## 4. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan mengenai Penerapan Algoritma Convolutional Neural Network (CNN) untuk Pengenalan Bahasa Isyarat Indonesia (BISINDO), dapat disimpulkan bahwa:

1. Model CNN yang diusulkan terbukti sangat efektif dalam mengklasifikasikan huruf alfabet BISINDO. Arsitektur custom CNN yang terdiri dari tiga lapisan konvolusi dan dua lapisan fully connected berhasil mencapai kinerja optimal dengan akurasi sebesar 98,5% pada data testing. Ini membuktikan kemampuan CNN dalam mengekstraksi fitur-fitur hierarkis yang relevan dari gambar bentuk tangan.
2. Kinerja model bersifat robust dan seimbang across different evaluation metrics. Nilai precision sebesar 97,8% menunjukkan bahwa model hampir tidak pernah menghasilkan false positive, sementara recall sebesar 98,2% mengindikasikan kemampuan model yang sangat baik dalam mendeteksi semua instance yang benar. Keseimbangan optimal antara precision dan recall tercermin dari F1-Score sebesar 98,0%, menegaskan konsistensi dan reliabilitas model.

## DAFTAR PUSTAKA

- Alhussan, A. A., Eid, M. M., & Lim, W. H. (2023). Advancing Communication for the Deaf: A Convolutional Model for Arabic Sign Language Recognition. *Journal of Artificial Intelligence and Metaheuristics*, 5(1), 38–45. <https://doi.org/10.54216/JAIM.050104>
- Awaludin, M., & Amelia, L. V. (2022). Penerapan Structural Equation Modeling (Sem) Dengan Lisrel Terhadap



- Perbedaan Tarif Penerbangan Pada Penumpang Domestik Di Bandara Halim Perdanakusuma. *Jurnal Sistem Informasi Universitas Suryadarma*, 9(1). <https://doi.org/10.35968/jsi.v9i1.855>
- Awaludin, M., & Gani, A. (2024). Pemanfaatan kecerdasan buatan pada algoritma k-means klastering dan sentiment analysis terhadap strategi promosi yang sukses untuk penerimaan mahasiswa baru. *JSI (Jurnal Sistem Informasi) Universitas Suryadarma*, 11(1), 1–6.
- Deshmukh, R., Lahamge, T., Phadatare, I., Shinde, D., & Manhas, R. (2024). A Comprehensive Review on Real-Time Sign Language Detection for Deaf and Dumb People. *Proceedings - 2024 3rd International Conference on Sentiment Analysis and Deep Learning, ICSADL 2024, April*, 169–176. <https://doi.org/10.1109/ICSADL61749.2024.00034>
- Ghuge, P. A. (2024). Sign language Detection and Recogniztion using Deep Learning. *Interantional Journal of Scientific Research in Engineering and Management*, 08(05), 1–5. <https://doi.org/10.55041/ijserem34640>
- Lee, J., & Park, H. M. (2023). Preliminary Study on Data Augmentation Methods for Sign Language Recognition. *International Conference on Control, Automation and Systems*, 886–889. <https://doi.org/10.23919/ICCAS59377.2023.10317044>
- Mishra, K., Akhand, H., Kantade, M., & Marmat, M. (2023). Sign Language Recognition Enabling Communication Strategies for Persons with Hearing Impairment. *International Journal of Innovative Research in Engineering*, 578–580. <https://doi.org/10.59256/IJIRE.2023040229>
- Mulla, R., Joshi, S., Devchakke, A., Dawda, A., & Durgude, A. (2025). Enhancing American Sign Language Recognition: A Comparative Study of LSTM and TensorFlow Zoo Models for Static and Non-Static Gesture Detection. *2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI)*. <https://doi.org/10.1109/IATMSI64286.2025.10985235>
- Prabu, S., Sridhar, T. K., Sridharan, S., Sukesh, D., & Rajavel, J. (2024). Revolutionizing Communication: A Hybrid Deep Learning Framework for Enhanced Sign Language Recognition. *2024 International Conference on Data Science and Network Security (ICDSNS)*. <https://doi.org/10.1109/ICDSNS62112.2024.10690996>
- Sanaullah, M., Kashif, M., Ahmad, B., Safdar, T., Hassan, M., Hasan, M. H., & Haider, A. (2022). Sign Language to Sentence Formation: A Real Time Solution for Deaf People. *Computers, Materials and Continua*, 72(2), 2501–2519. <https://doi.org/10.32604/cmc.2022.021990>
- Shi, P., & Huang, H. (2022). Lightweight MobileNetV2 offline handwritten Chinese character recognition based on attention mechanism. *International Symposium on Robotics, Artificial Intelligence, and Information Engineering*, 83. <https://doi.org/10.1117/12.2659091>
- Srivastava, S. (2025). Intelligent Hand Gesture Recognition for Sign Language Understanding. *2025 6th International Conference on Data Intelligence and Cognitive Informatics (ICDICI)*, 317–322. <https://doi.org/10.1109/ICDICI66477.2025.11135319>
- Weng, Z., Zhang, X., Mou, Y., Yi, C., Li, F., Bashivan, P., & Xu, P. (2024). A Hybrid CNN-Transformer Approach for Continuous Fine Finger Motion Decoding from sEMG Signals. *2024 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*. <https://doi.org/10.1109/CIVEMSA58715.2024.10586636>