

## Problématique

- Interfaces de contrôle des bras robotisés encore complexes et peu intuitives
- Besoin d'une interaction plus naturelle basée sur les gestes humains
- Nécessité d'une reconnaissance fiable, robuste et généralisable à différents utilisateurs

## Objectifs

L'objectif global du projet est de développer une solution de reconnaissance de gestes inertiels basée sur l'IA pour un contrôle robotique naturel. Plus spécifiquement, il s'agira de :

- Concevoir un système d'acquisition de données et constituer un dataset inertiel multi-utilisateurs équilibré ;
- Développer et comparer des modèles de reconnaissance gestuelle robustes basés sur l'apprentissage profond ;
- Intégrer et valider le modèle dans un environnement de simulation pour le contrôle d'un bras robotisé (PyBullet).

## Méthodologie

Chaîne complète de traitement des données inertielles, de l'acquisition à la simulation, structurée en trois étapes :

### Acquisition et structuration des données

- Acquisition via ESP32 et capteurs IMU
- Dataset multi-utilisateurs équilibré

### Prétraitement et apprentissage

- Segmentation et standardisation (64 échantillons)
- Enrichissement (magnitudes, variations)
- Modèles : MLP, CNN1D, BiLSTM, CNN-BiLSTM

## Simulation et application

- Intégration dans PyBullet
- Contrôle simulé d'un bras robotisé

**Technologies utilisées** : ESP32, capteurs IMU (MPU6050), Python (TensorFlow/Keras), Flask, PyBullet, Flask, SQLite.

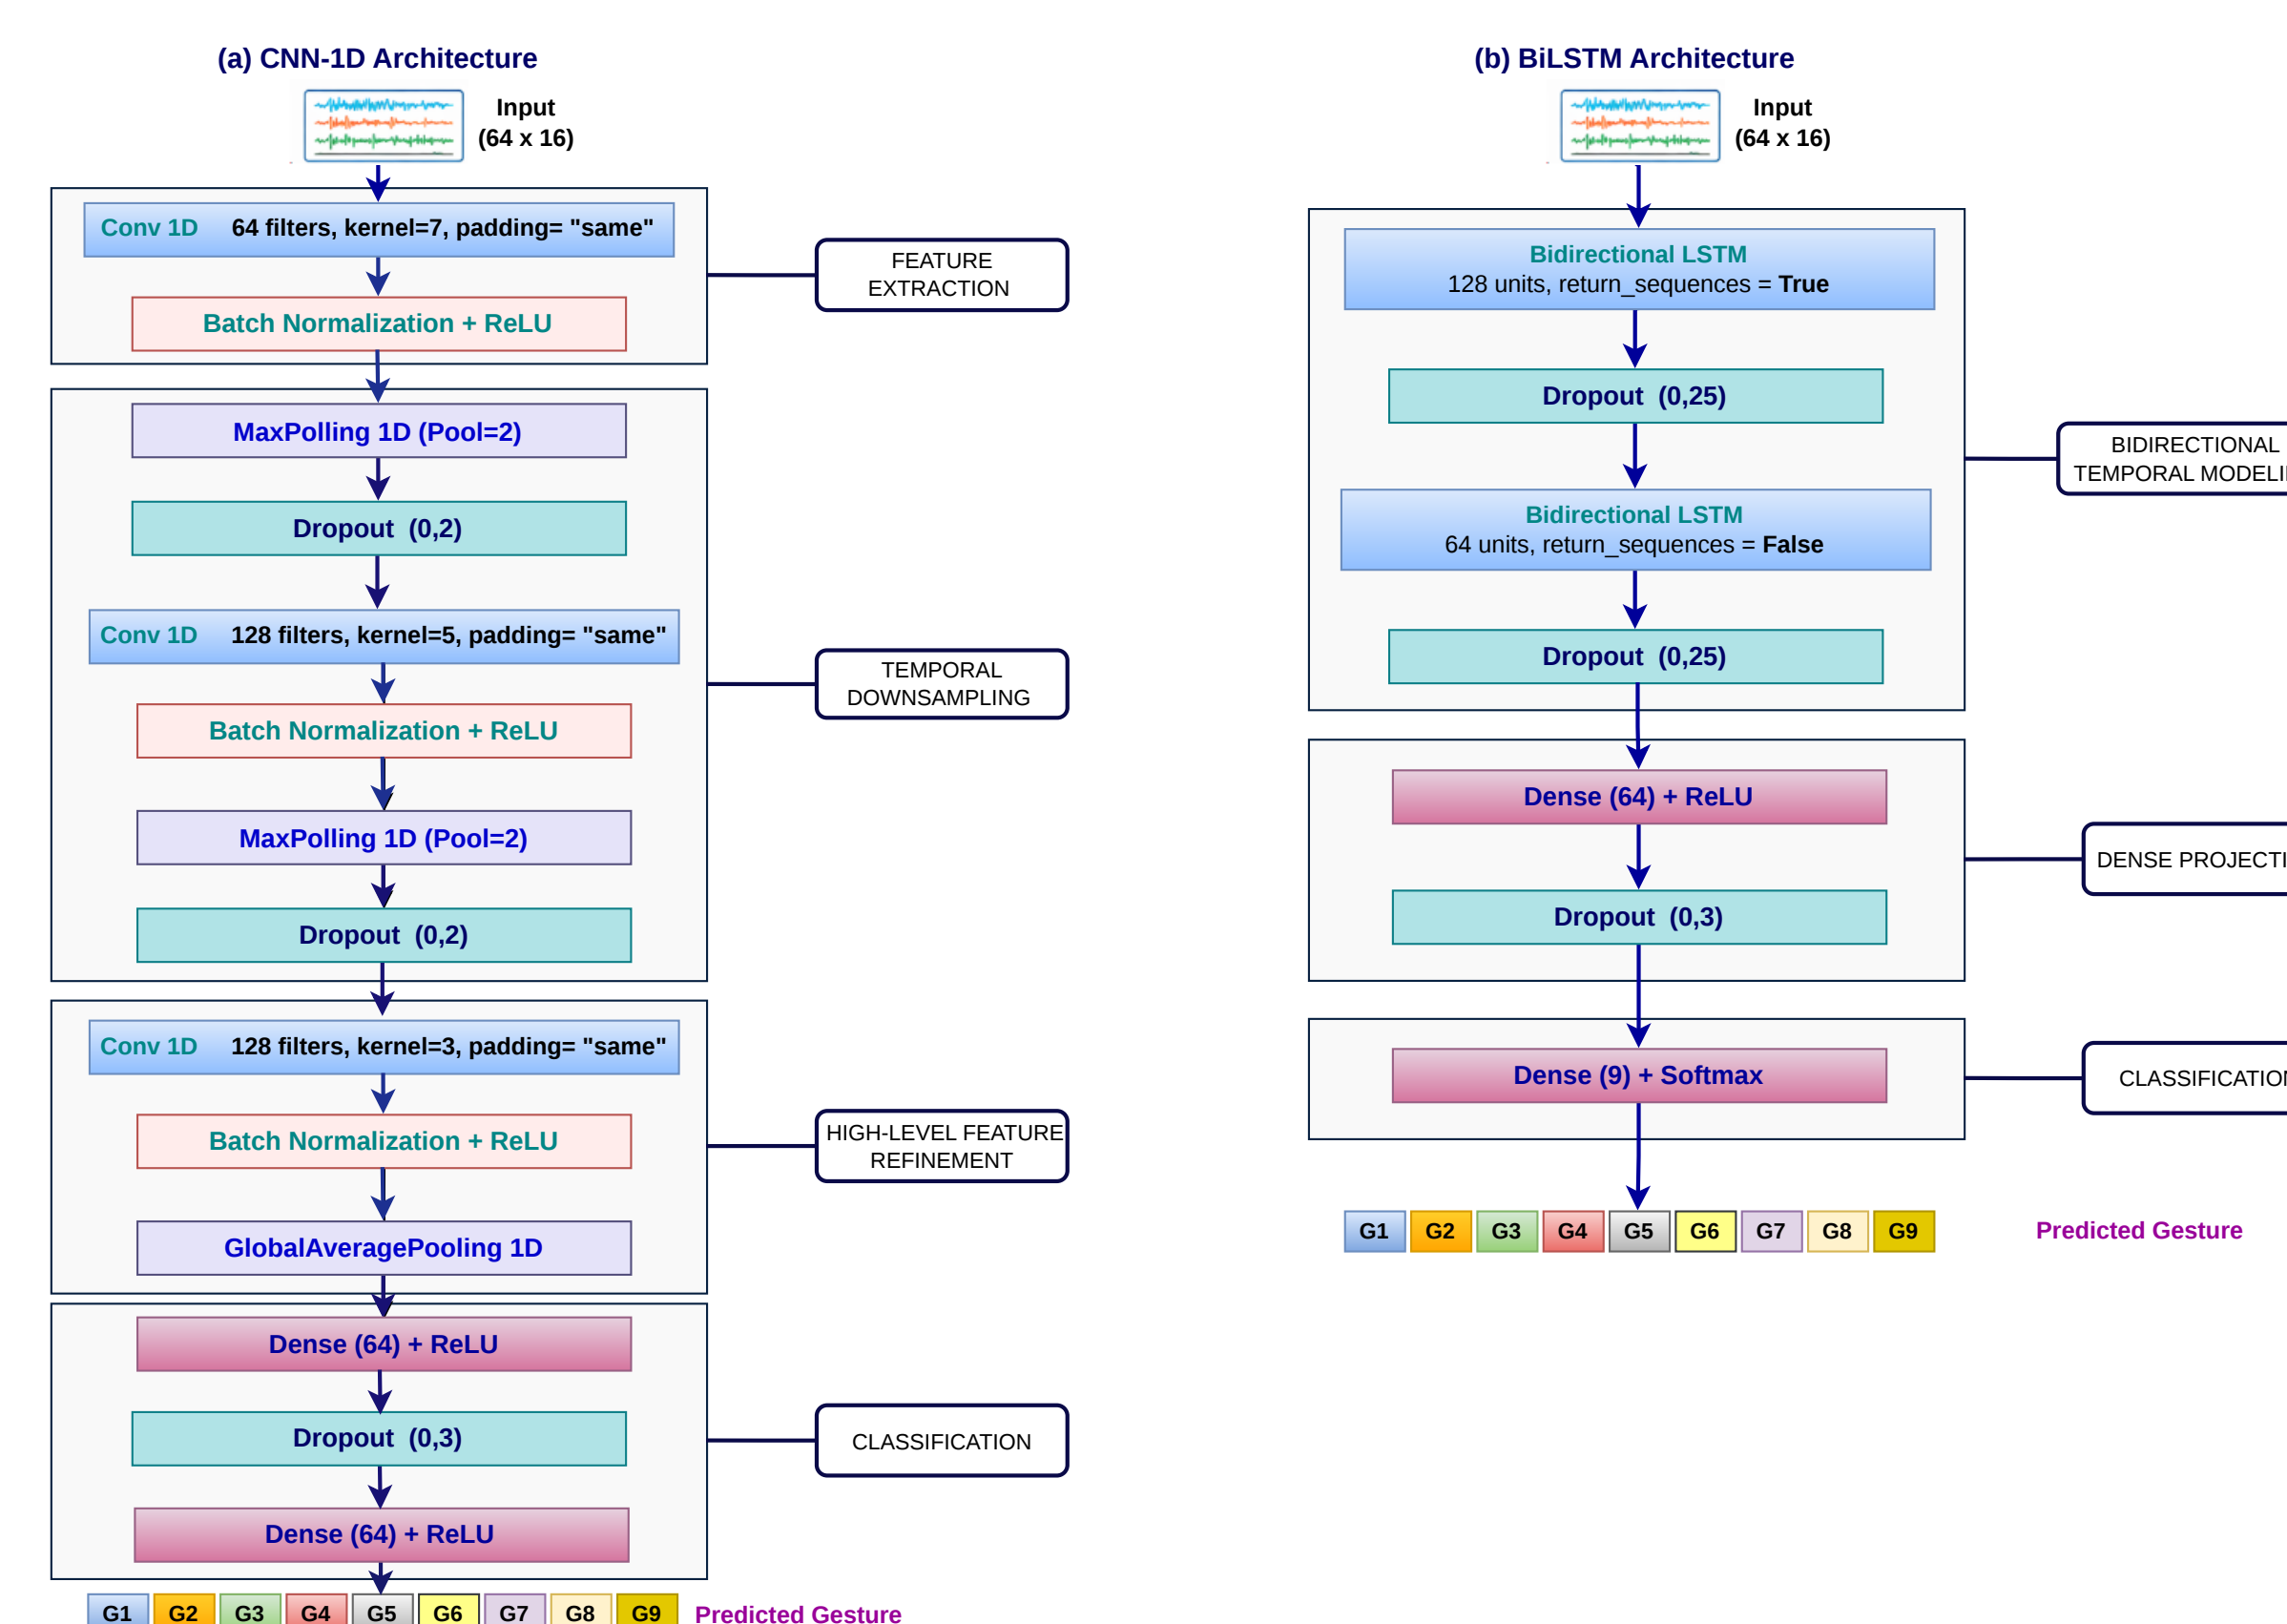


FIGURE 1 – Architectures des meilleurs modèles : (a) CNN1D et (b) BiLSTM.

## Évaluation

- Protocole **LOSO** pour évaluer la généralisation à de nouveaux utilisateurs ;
- Comparaison avec un **split classique** et prévention du data leakage (normalisation sur train uniquement) ;
- Évaluation via les métriques : Accuracy, Precision, Recall et F1-score.

## Résultats

TABLE 1 – Comparaison des performances des modèles.

Modèle	Acc (%)	Prec (%)	Rec (%)	F1 (%)
MLP	75.33	76.15	75.33	74.86
CNN1D	<b>86.85</b>	<b>88.42</b>	<b>86.85</b>	<b>86.70</b>
BiLSTM	86.30	86.93	86.30	85.98
CNN-BiLSTM	85.67	86.75	85.67	85.35

TABLE 2 – Classes de gestes utilisées dans les matrices de confusion.

Code Classe de geste	Code Classe de geste
A Abaissement de la main	F Mouvement vers la gauche
B Mouvement vers l'avant (pousser)	G Main ouverte
C Fermeture de la main (poing)	H Mouvement vers l'arrière (tirer)
D Élévation de la main	I Rotation du poignet
E Mouvement vers la droite	

TABLE 3 – Matrice de confusion du modèle CNN1D.

	A	B	C	D	E	F	G	H	I
A	<b>94.0</b>	4.0	0.0	0.0	0.3	0.0	0.3	1.3	0.0
B	2.0	<b>76.0</b>	1.7	0.3	0.7	0.0	0.0	19.3	0.0
C	0.0	4.3	<b>84.7</b>	0.7	0.7	0.0	9.7	0.0	0.0
D	0.0	3.0	0.0	<b>94.7</b>	0.0	0.3	0.3	1.7	0.0
E	0.0	7.0	0.0	0.0	<b>92.0</b>	0.0	0.0	1.0	0.0
F	0.3	0.7	0.0	0.3	0.0	<b>96.3</b>	0.0	2.3	0.0
G	0.0	0.3	19.3	0.0	0.0	0.3	<b>75.3</b>	4.7	0.0
H	0.3	26.7	0.3	0.7	0.7	0.7	0.0	<b>70.7</b>	0.0
I	0.0	0.7	0.3	0.0	0.3	0.7	0.0	0.0	<b>98.0</b>

- Les modèles temporels surpassent le MLP (+11%), confirmant l'importance de la dynamique des signaux ;
- Le **CNN1D** est le plus performant, et l'évaluation LOSO garantit une bonne généralisation.

## Conclusion et perspectives

Ce travail démontre l'efficacité des capteurs inertiels pour le contrôle gestuel d'un bras robotisé, avec des performances élevées du modèle CNN1D. Comme perspectives :

- Mise en œuvre d'un contrôle temps réel du bras robotisé dans PyBullet
- Déploiement embarqué sur microcontrôleur

## Références

- [1] S. Zhang, S. Li, S. Zhang, F. Shahabi, S. Xia, Y. Deng, and N. Alshurafa, "Deep Learning in Human Activity Recognition with Wearable Sensors : A Review on Advances," *Sensors*, vol. 22, no. 4, p. 1476, 2022.
- [2] A. Dahiya, D. Wadhwa, R. Katti, and L. G. Occhipinti, "Efficient Hand Gesture Recognition Using Artificial Intelligence and IMU-Based Wearable Device," *IEEE Sensors Letters*, vol. 8, no. 12, pp. 1–4, 2024.