

9ª Jornada de Jóvenes Investigadores de Química y Física de Aragón, 16/12/2021

Brain-Computer Interface basada en el procesado de EEG *on the edge* para reconocimiento de tareas de imaginación motora

Daniel Enériz, Ana Caren Hernández-Ruiz, Nicolás Medrano y Belén Calvo
{**eneriz**, anaacaren, nmedrano, becalvo}@unizar.es Grupo de Diseño Electrónico (GDE-I3A)

Brain-Computer Interfaces (BCIs)

Daniel Enériz
eneriz@unizar.es

MIBCI-QCNNs



1. Introducción

2. Materiales y
métodos



3. Resultados

4. Conclusión

- Comunicación entre humanos y maquinas




- Diferentes campos de aplicación




Motor imagery (Imagen motora)

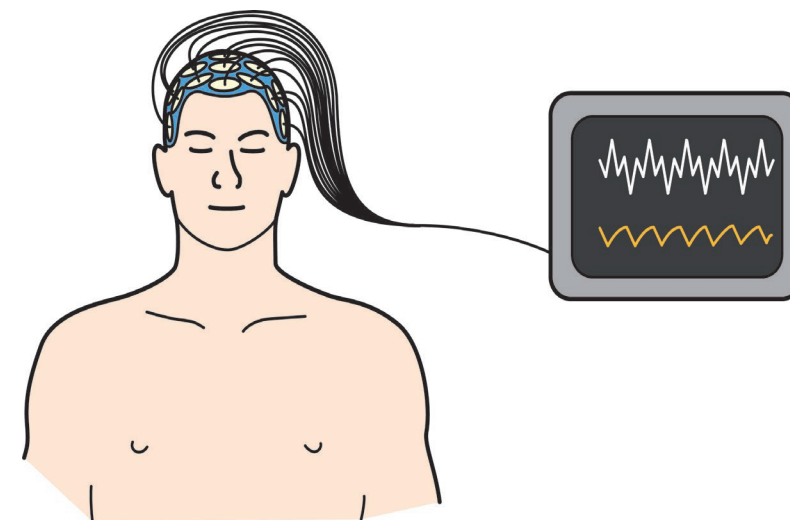
- Uno de los paradigmas más populares en BCIs
- Simulación mental de movimientos reales
- Cada movimiento actúa como un *trigger* de la BCI



- Señales relacionadas con la actividad cerebral más populares
- Fáciles de adquirir y no invasivas



"Brain Computer Interface / g-tech medical engineering" by Ars Electronica is licensed under CC BY-NC-ND 2.0



"EGG" by The Clear Communication People is licensed with CC BY-NC-ND 2.0. To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc-nd/2.0/>

Feature extractor

- CSP
- ICA
- WT

+

Classifier

- SVM
- kNN
- DT

Convolutional Neural Networks (CNNs)

[2] Lawhern, V.J.; Solon, A.J.; Waytowich, N.R.; Gordon, S.M.; Hung, C.P.; Lance, B.J. EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain-Computer Interfaces. *J. Neural Eng.* **2018**, *15*, 056013, doi:10.1088/1741-2552/aace8c.

- Dos alternativas

Cloud Computing

Conexión activa a internet

- Gran consumo de energía
- Posible pérdida de privacidad

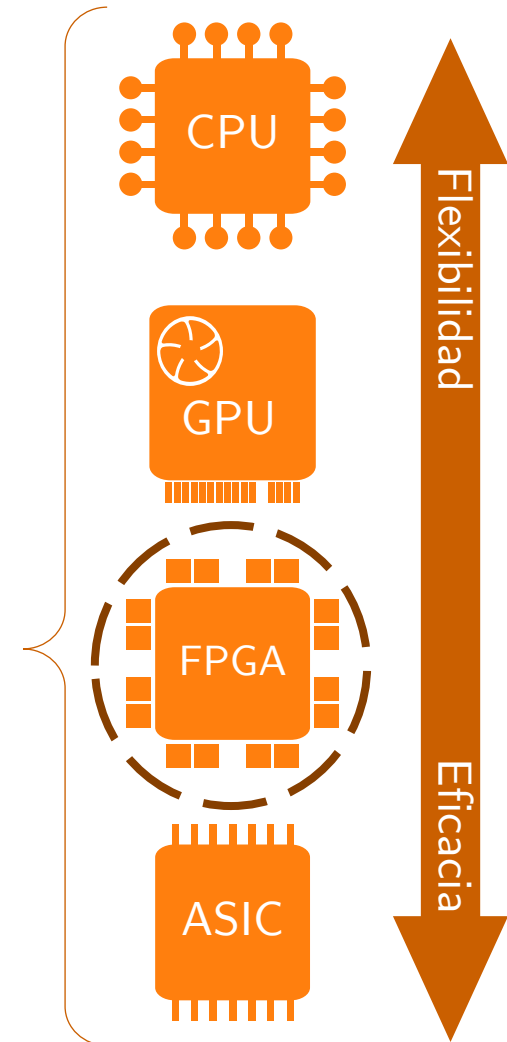
Menos requisitos computacionales

Edge Computing

Sin conexión activa a internet

- Menos consumo de energía
- Sin pérdida de privacidad

Más requisitos computacionales



Daniel Enériz
eneriz@unizar.es


MIBCI-QCNNs

1. Introducción


2. Materiales y
métodos

3. Resultados

4. Conclusión



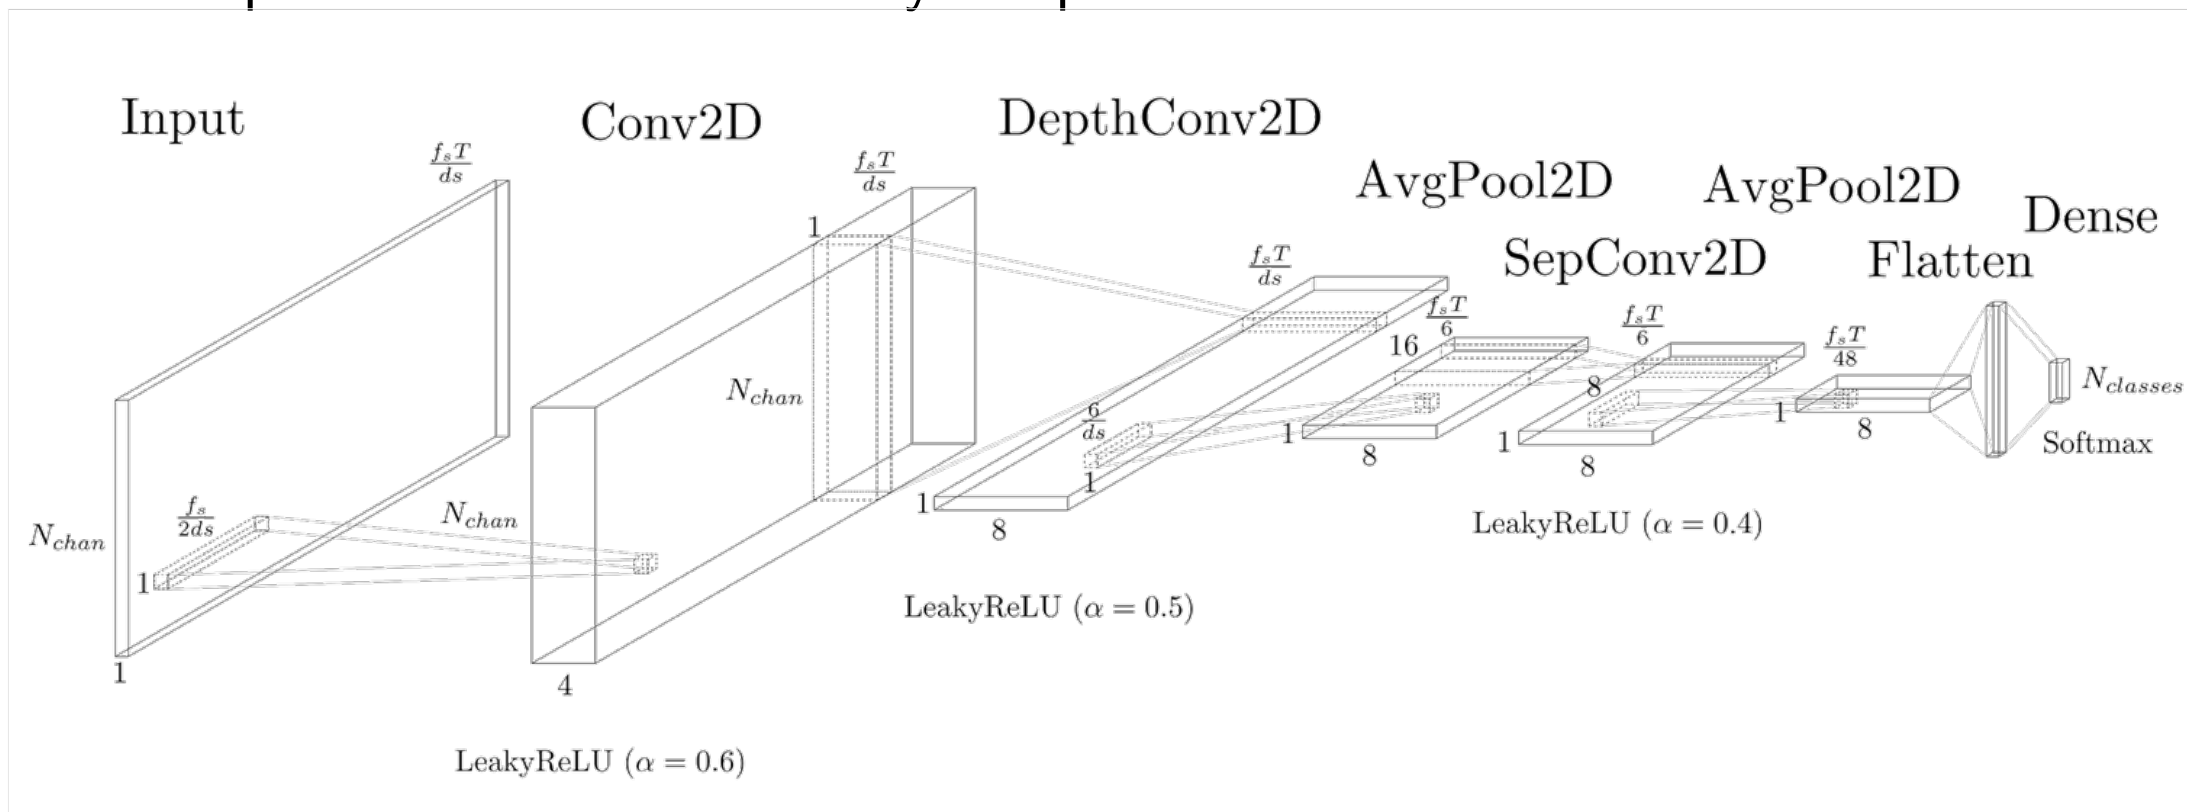
- *Physionet Motor Movement/Imagery dataset*
- 105 sujetos: 64 canales de EEG @ 160 Hz
- 4 clases:
 - L: Imaginar abrir y cerrar puño izquierdo
 - R: Imaginar abrir y cerrar puño derecho
 - 0: Descansar
 - F: Imaginar abrir y cerrar ambos pies
- Parametrización:
reducción del dataset → reducción del modelo



N _{classes}	2	3	4
Labels	L/R	L/R/0	L/R/0/F

[4] Goldberger, A.L.; Amaral, L.A.N.; Glass, L.; Hausdorff, J.M.; Ivanov, P.Ch.; Mark, R.G.; Mietus, J.E.; Moody, G.B.; Peng, C.-K.; Stanley, H.E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* **2000**, *101*, doi:10.1161/01.CIR.101.23.e215.

- Basada en la EEGNet-4,2, adaptada al dataset (parametrizado)
 - Sustitución de la ELU por la LeakyReLU (implementación más simple)
 - Capas BatchNormalization y Dropout eliminadas



Resultados: *Validation accuracy (%)*

Daniel Enériz
eneriz@unizar.es

MIBCI-QCNNs


1. Introducción

2. Materiales y
métodos

3. Resultados

4. Conclusión

N_{classes}	Dose et al. [1]		Wang et al. [2]		Proposed work			
	Global	SS-TL	Global	SS-TL	$ds = 1$		$ds = 2$	
					Global	SS-TL	Global	SS-TL
2	80.38	86.49	82.43	84.32	83.15	87.46	82.52	93.10
3	69.82	76.25	75.07	80.07	75.74	83.26	75.34	93.21
4	58.59	68.51	65.07	70.83	65.75	74.31	65.56	89.23



[1] Dose, H.; Møller, J.S.; Iversen, H.K.; Puthusserypady, S. An End-to-End Deep Learning Approach to MI-EEG Signal Classification for BCIs. *Expert Systems with Applications* **2018**, *114*, 532–542, doi:10.1016/j.eswa.2018.08.031.

[2] Lawhern, V.J.; Solon, A.J.; Waytowich, N.R.; Gordon, S.M.; Hung, C.P.; Lance, B.J. EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain–Computer Interfaces. *J. Neural Eng.* **2018**, *15*, 056013, doi:10.1088/1741-2552/aace8c.

Efecto del paso a FPGA

Daniel Enériz
eneriz@unizar.es

MIBCI-QCNNs


1. Introducción

2. Materiales y
métodos

3. Resultados

4. Conclusión

- Modelo elegido: $T=3s$, $ds=2$, $N_{\text{chan}}=64$, $N_{\text{classes}}=4$
- Validation accuracy tras el entrenamiento: **65.56%**
- Validation accuracy tras implementación (16,8): **65.45%**
- Diferencia: **0.11%** ← Negligible!



Daniel Enériz
eneriz@unizar.es

MIBCI-QCNNs

1. Introducción

2. Materiales y
métodos

3. Resultados

4. **Conclusión**

- BCI basada en MI con procesamiento de EEG *on the edge*
- Adaptación de la EEGNet:
 - Para trabajar con el dataset de MI de Physionet
 - Con reducción parametrizada
- Implementación con datos de punto fijo
 - Menos consumo de recursos: FPGAs de bajo coste
 - Pérdida de *accuracy* negligible

9ª Jornada de Jóvenes Investigadores de Química y Física de Aragón, 16/12/2021

¡Gracias! ¿Preguntas?

Daniel Enériz, Ana Caren Hernández-Ruiz, Nicolás Medrano y Belén Calvo
{**eneriz**, anaacaren, nmedrano, becalvo}@unizar.es Grupo de Diseño Electrónico (GDE-I3A)