

Navarra
Artificial Intelligence
Research

NAR
CENTER

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES

Instituto de Ciencia de los Datos e
Inteligencia Artificial

28-06-24

Áreas de Investigación



Análisis y fusión inteligente de información y datos

Esta área de investigación pretende ahondar en la descripción, análisis y explotación de la información y los datos. Incluyendo aspectos como el estudio del manejo de incertidumbre, el desarrollo de diferentes formas de representación de la información y los datos o la detección de características relevantes o interrelaciones.



Aprendizaje inteligente

Esta área está enfocada en el estudio y desarrollo de sistemas, algoritmos y modelos que permiten a las computadoras aprender y tomar decisiones basadas en datos sin una programación explícita.



IA disruptiva

Esta área de investigación pretende estudiar y aplicar tecnologías de inteligencia artificial de manera innovadora y revolucionaria con el objetivo fundamental de cambiar la forma en que operan las industrias, los negocios y la sociedad en su conjunto. Con ello se pretende no solo mejorar los procesos existentes, sino también transformar la manera en que se hacen las cosas, creando nuevos paradigmas y oportunidades.



IA y sociedad

Esta área de investigación se centra en comprender el impacto y la interacción entre la inteligencia artificial y la sociedad en su conjunto. Su objetivo es investigar cómo la IA afecta a la vida de las personas, las organizaciones, la economía y la política, y cómo la sociedad, a su vez, influye en el desarrollo y la adopción de la IA.

Proyectos

BIDEONENA -
Técnicas de
Inteligencia
Artificial para la
reducción del
consumo
energético en
robótica móvil



UPNA Green
Smart &
Sustainable
Campus



Optimización del
Diseño y Control
de
Aerogeneradores



IA explicable:
Modelos
Teóricos y
Aplicaciones en
Datos
Heterogéneos
Multiatributo



Comportamiento
del Consumidor
en Aplicaciones
de Salud Móvil
(mHealth)



AI4FLOOD:
adaptación y
mejora de la
prevención
municipal frente
a inundaciones
mediante la
integración de
Inteligencia
Artificial y la
participación
ciudadana



Frágil-IA:
Inteligencia
artificial para la
atención
personalizada a
la fragilidad



Rehabilitación
Postictus con
Interfaces
Cerebro-
Ordenador (BCI)



Equipo

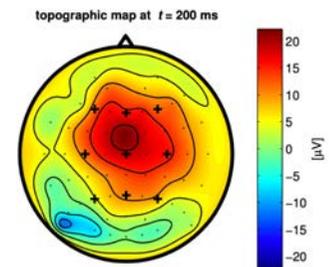
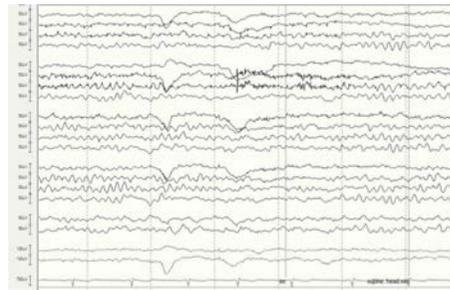
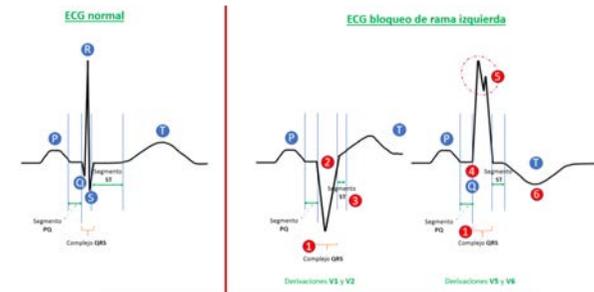
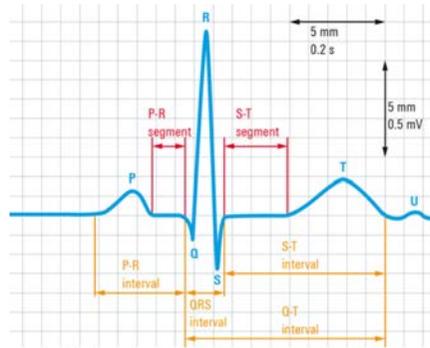
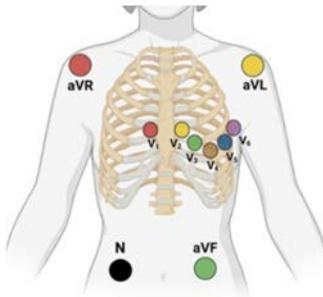


DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES

- Introducción: Señales de electrocardiografía (ECG) y señales de electroencefalografía (EEG).
- Deep learning aplicado a ECG.
- Deep learning en EEG.



DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Introducción

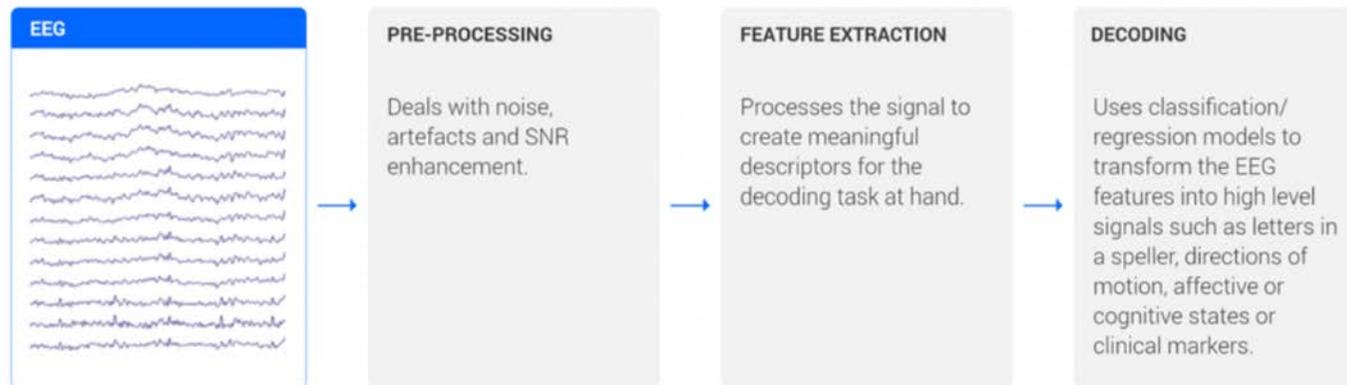


Fuente: Compumedics

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Introducción

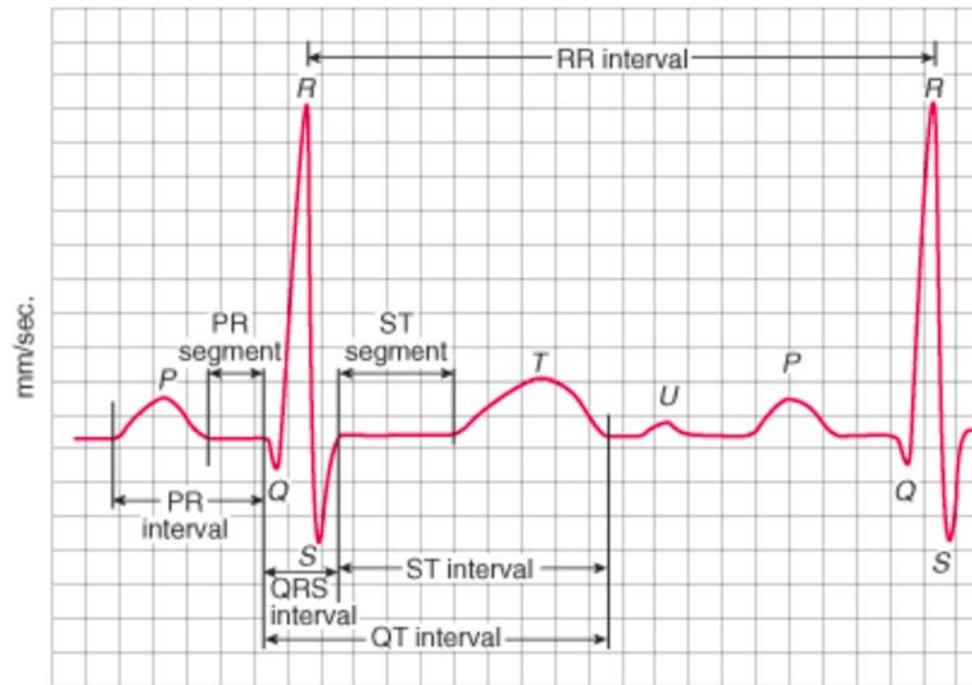
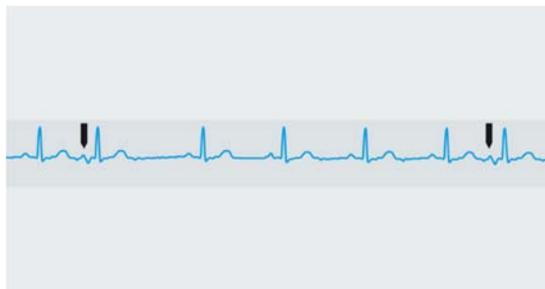
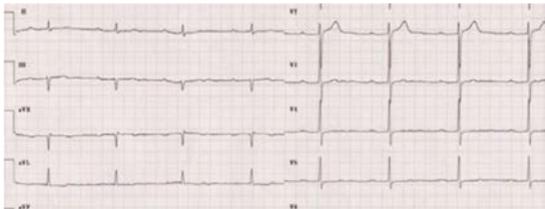
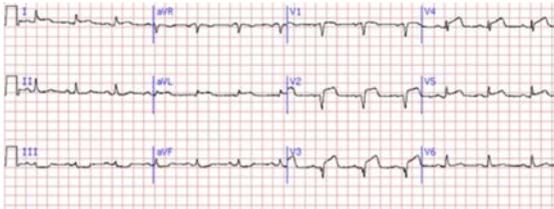
¿Por qué necesitamos aprendizaje automático para procesar datos de ECG y EEG?

- Las señales adquiridas son ruidosas, baja relación señal/ruido, retrasos entre canales, etc...
- Es necesario hacer un procesamiento de los datos registrados antes de ser examinados por clínicos.
- Para mejorar la relación señal/ruido, limpiar la señal de artefactos, extraer características de la misma y decodificar e interpretar las señales.



Fuente:Bitbrain

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y ECG



mm/mV 1 square = 0.04 sec/0.1mV

Técnicas de machines learning utilizadas

Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior.	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración.

Técnicas de machines learning utilizadas

Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior,	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración*.
Chuanq et al. [4]	DL	Maneja datos de gran tamaño y complejidad. Es más eficiente.	Tiene un problema de desbalanceo de clases. Es caro desde un punto de vista computacional.

Técnicas de machines learning utilizadas

Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior.	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración*.
Chuanq et al. [4]	DL	Maneja datos de gran tamaño y complejidad. Es más eficiente.	Tiene un problema de desbalanceo de clases. Es caro desde un punto de vista computacional.
Yong et al. [5]	XDM	Se utiliza para mejorar la transparencia de aplicación en la práctica clínica.	Incapaz de determinar el factor particular del complejo QRS. Es difícil tratar esta condición en el mapa de prominencia.

Técnicas de machines learning utilizadas

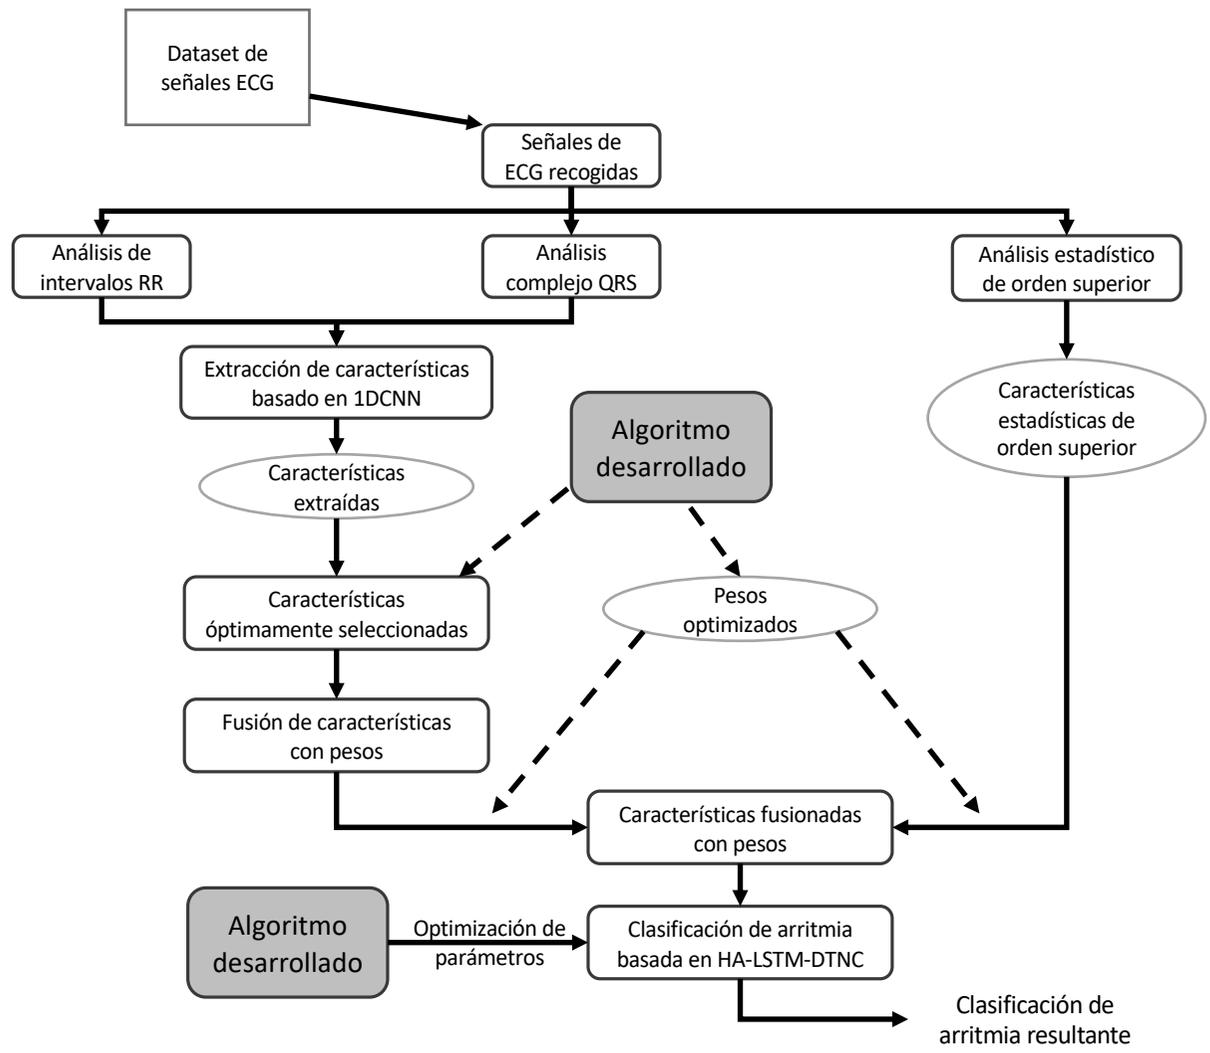
Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior,	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración*.
Chuanq et al. [4]	DL	Maneja datos de gran tamaño y complejidad. Es más eficiente.	Tiene un problema de desbalanceo de clases. Es caro desde un punto de vista computacional.
Yong et al. [5]	XDM	Se utiliza para mejorar la transparencia de aplicación en la práctica clínica.	Incapaz de determinar el factor particular del complejo QRS. Es difícil tratar esta condición en el mapa de prominencia.
Yuanlu et al. [6]	CNN	Se utiliza para diferentes tareas de clasificación. Es apropiado para analizar datos temporales.	Tiene un problema de sobreajuste. Tiene explosión del gradiente.

Técnicas de machines learning utilizadas

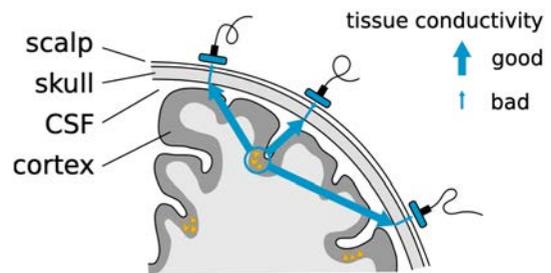
Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior.	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración*.
Chuanq et al. [4]	DL	Maneja datos de gran tamaño y complejidad. Es más eficiente.	Tiene un problema de desbalanceo de clases. Es caro desde un punto de vista computacional.
Yong et al. [5]	XDM	Se utiliza para mejorar la transparencia de aplicación en la práctica clínica.	Incapaz de determinar el factor particular del complejo QRS. Es difícil tratar esta condición en el mapa de prominencia.
Yuanlu et al. [6]	CNN	Se utiliza para diferentes tareas de clasificación. Es apropiado para analizar datos temporales.	Tiene un problema de sobreajuste. Tiene explosión del gradiente.
Cui, J. et al. [7]	FFBPNN	Se emplea para utilizar los diferentes tipos de latido de corazón. Obtiene mejor rendimiento en clasificación ECG.	Tiene ruido heredado. Ignora algunas características esenciales.

Técnicas de machines learning utilizadas

Autor	Metodología	Características	Debilidades
EssaandXie [1]	CNN	Se reducen errores específicos (falsos positivos o falsos negativos) y, como resultado, ofrece un rendimiento de clasificación superior,	Produce sobreajuste, explosión del gradiente y desbalanceo de clases. El modelo no falla inmediatamente.
Singh et al. [2]	DNN	Se logra una mayor precisión en la detección. Obtiene mejores resultados en comparación con el algoritmo existente.	El mejor tamaño de la capa oculta se obtiene por GSA, entrenada con la función de pérdida de Dice.
J. J. Huang et al.[3]	STFT	Este clasificador logra mayor precisión con el coste más bajo. Se utiliza como entrada al modelo propuesto, y es un método simple y eficiente.	Tiene marcos de tiempo más pequeños que causan el problema de filtración*.
Chuanq et al. [4]	DL	Maneja datos de gran tamaño y complejidad. Es más eficiente (Hybrid Convolutional Transformer Network)	Tiene un problema de desbalanceo de clases. Es caro desde un punto de vista computacional.
Yong et al. [5]	XDM	Se utiliza para mejorar la transparencia de aplicación en la práctica clínica.	Incapaz de determinar el factor particular del complejo QRS. Es difícil tratar esta condición en el mapa de prominencia.
Yuanlu et al. [6]	CNN	Se utiliza para diferentes tareas de clasificación. Es apropiado para analizar datos temporales.	Tiene un problema de sobreajuste. Tiene explosión del gradiente.
Cui, J. et al. [7]	FFBPNN	Se emplea para utilizar los diferentes tipos de latido de corazón. Obtiene mejor rendimiento en clasificación ECG.	Tiene ruido heredado. Ignora algunas características esenciales.
Shadhon et al. [8]	2D-CNN	Se obtienen mejores resultados comparados otros algoritmos existentes. Es sencillo de analizar y programar.	El rendimiento depende de los datos de entrada. Es una red muy sensible al ruido en los datos.

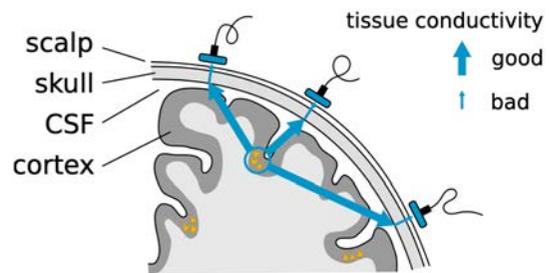


DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG



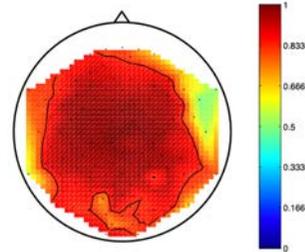
La señal llega a diferentes lugares del cuero cabelludo con casi la misma intensidad debido a las diferentes conductividad del tejido.

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG



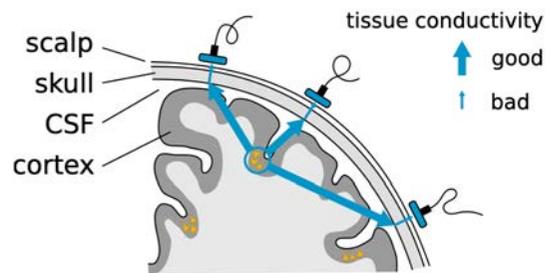
La señal llega a diferentes lugares del cuero cabelludo con casi la misma intensidad debido a las diferentes conductividad del tejido.

- ▶ Las señales sin procesar de EEG están asociadas con una resolución espacial pequeña debido al volume conduction.
- ▶ Por ejemplo en estos datos la mayoría de los canales están altamente correlados:



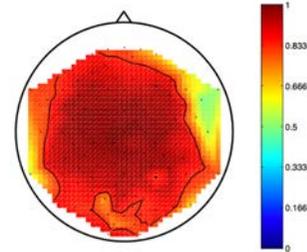
El mapa muestra el coeficiente de correlación de cada canal con el canal Cz (localizado en el centro de la cabeza).

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG



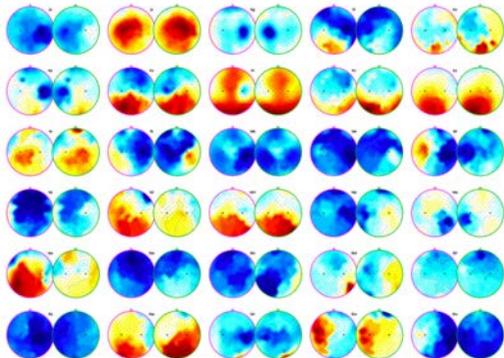
La señal llega a diferentes lugares del cuero cabelludo con casi la misma intensidad debido a las diferentes conductividad del tejido.

- ▶ Las señales sin procesar de EEG están asociadas con una resolución espacial pequeña debido al volume conduction.
- ▶ Por ejemplo en estos datos la mayoría de los canales están altamente correlados:

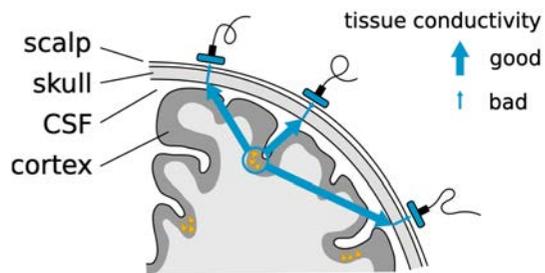


El mapa muestra el coeficiente de correlación de cada canal con el canal Cz (localizado en el centro de la cabeza).

- ▶ Variabilidad entre sujetos

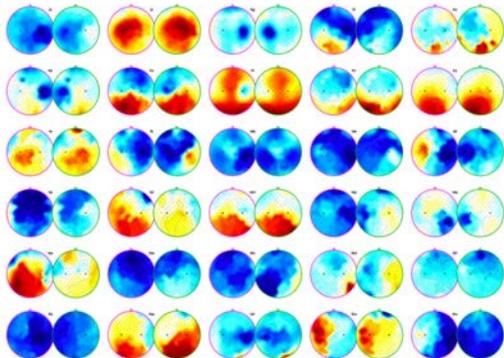


DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG

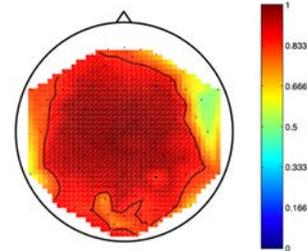


La señal llega a diferentes lugares del cuero cabelludo con casi la misma intensidad debido a las diferentes conductividad del tejido.

► Variabilidad entre sujetos



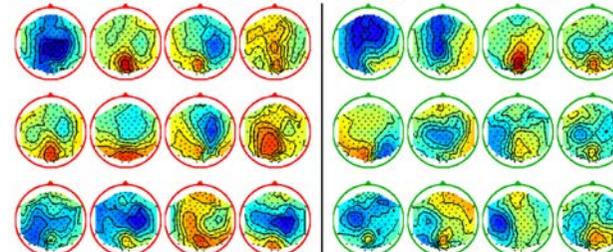
- Las señales sin procesar de EEG están asociadas con una resolución espacial pequeña debido al volume conduction.
- Por ejemplo en estos datos la mayoría de los canales están altamente correlados:



El mapa muestra el coeficiente de correlación de cada canal con el canal Cz (localizado en el centro de la cabeza).

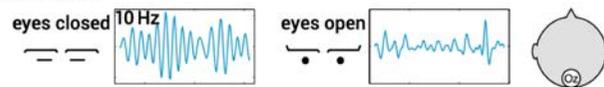
- Entre sujetos
- De una sesión a otra
- De un trial a otro

imaginación del movimiento mano izquierda imaginación del movimiento mano derecha
left hand imagery right hand imagery



DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG

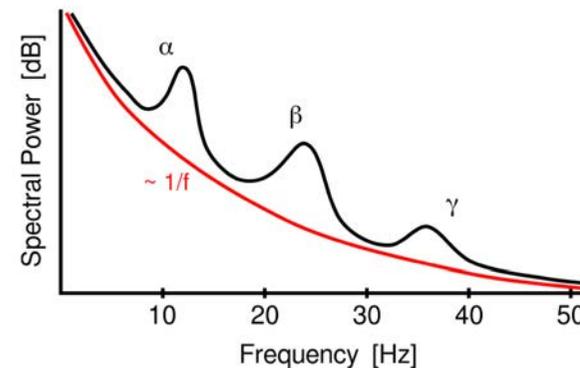
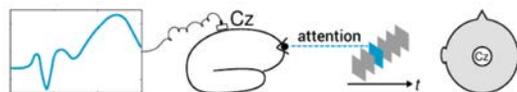
- ▶ **oscilaciones espontáneas**, p.ej. ritmos sensorimotores (SMR) o el ritmo visual alfa



- ▶ **oscilaciones inducidas**, p.ej., steady-state visual evoked potentials (SSVEP), evocados por y síncronos con un estímulo periódico externo

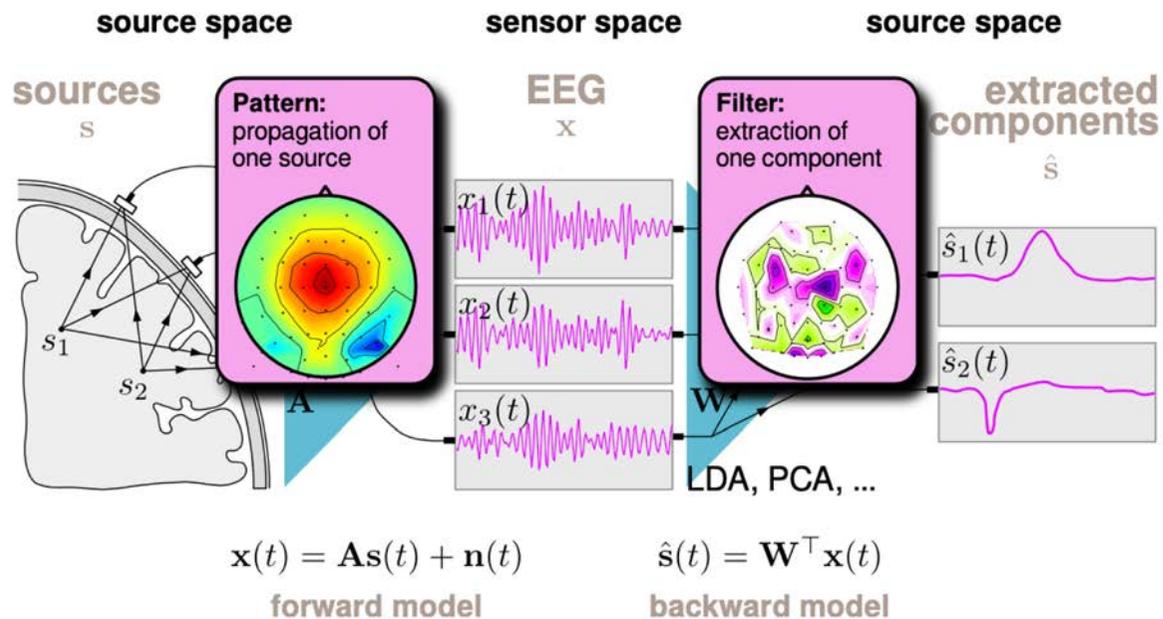


- ▶ **actividad transitoria**, event-related potentials (ERPs), time-locked a un evento, en general un estímulo externo; modulado por la atención



- ▶ La figura muestra un espectro idealizado.
- ▶ Algunos ritmos cerebrales se nombran según su origen, e.g., μ , α son en la misma banda pero de origen diferente (motor vs. occipital).

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Deep learning y EEG



Cada columna de A es un **patrón** espacial: la propagación de una fuente a los sensores.

Cada fila de W^T es un **filtro** espacial: ponderación de los canales de EEG.

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. Introducción

Desafíos de deep learning en EEG

- Adquisición de los datos
- Información limitada

Uso del deep learning para la decodificación de EEG

- Extracción de características y decodificación simultanea
- Enfoque supervisado
- Técnicas más usadas son CNN y RNN
- En el meta análisis realizado Yannick Roy et al. (2019 J. Neural Eng. S) se calcula una mejora media en la precisión del 5.4% en diferentes campos donde se usan datos EEG.

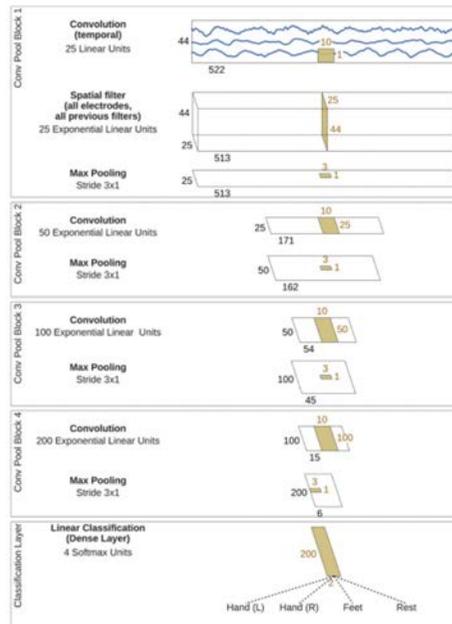
DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES.

Convolutional Neural Networks

- Pueden entenderse como filtros espaciales de variación de desplazamiento sobre la imagen.
- Aprenden características locales que se utilizan para crear características en capas profundas de la red.
- Pueden usarse para crear filtros en el tiempo y frecuencia.

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. CNN decodificación de imaginación de movimiento

Deep learning with convolutional neural networks for EEG decoding and visualization



Human Brain Mapping, Volume: 38, Issue: 11, Pages: 5391-5420, First published: 07 August 2017, DOI: (10.1002/hbm.23730)

Shirrmeyer, 2017.

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. CNN-RNN decodificación del sueño (modelo sleepnet)

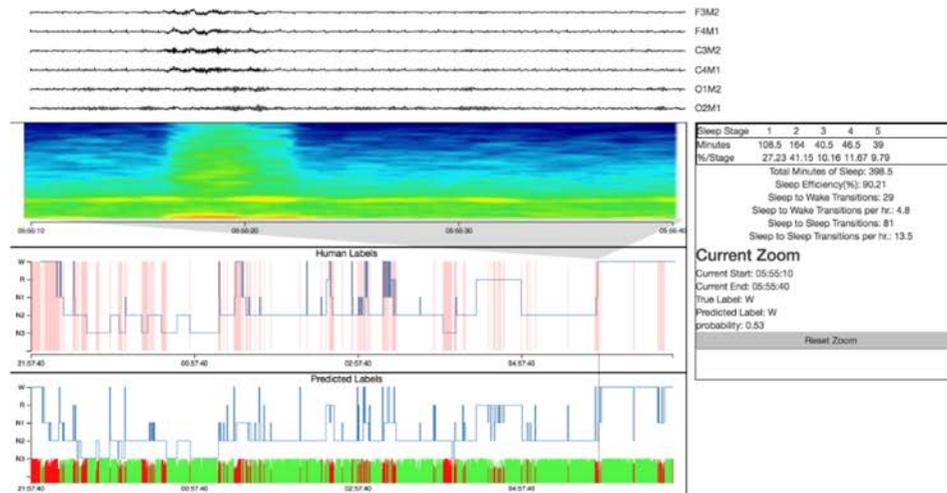
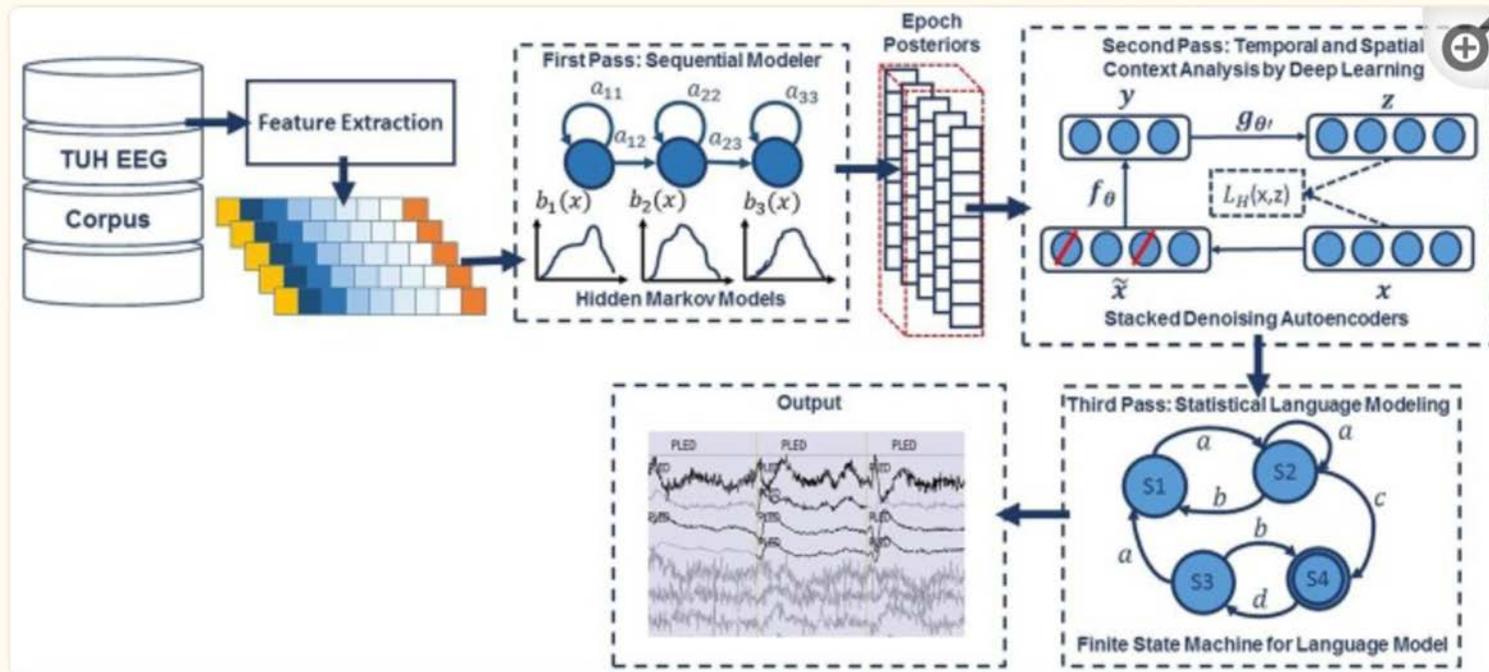


Figure 1: Web interface of SLEEPNET. In top-panel 1 and 2 we plot the raw EEG data the corresponding spectrogram. Below them, we show the ground truth (staging performed by a clinical expert) and SLEEPNET predicted labels and algorithm's confidence (red means low confidence while green means high confidence). On the right hand-side is a panel showing sleep related summary statistics.

DEEP LEARNING Y PROCESAMIENTO DE BIOSEÑALES. CNN- Hidden Markov models (Detección de epilepsia)



Referencias

- W. Lu, L.u. Weijia, An arrhythmia classification algorithm using C-LSTM in physiological parameters monitoring system under internet of health things environment, *J. Ambient Intell. Human. Comput.* (2021).
- Hannun, and Turakhia,, Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms use a deep neural network, *Nat. Med.* 25 (2019) 65–69.
- J.R.P. Arredondo, P. de Sousa, Classification of mechanisms underlying cardiac arrhythmias by deep learning, *Res. Biomed. Eng.* 36 (2020) 475–487.
- Kuila and Subhankar Joardar, ECG signal classification to detect heart arrhythmia using ELM and CNN, *Multimedia Tools Appl.* (2022).
- M. Thirugnanam, M.S. Pasupuleti, Cardiomyopathy -induced arrhythmia classification and pre-fall alert generation using Convolutional Neural Network and Long Short-Term Memory model, *Evol. Intel.* 14 (2021) 789–799.
- J. Li, X.u. Fangzhou, P. Ji, Shuwang Zhou, Minglei Shu, Two-dimensional ECG- based cardiac arrhythmia classification using DSE-ResNet, *Sci. Report* 12 (2022) 14485.
- S.T. Sanamdikar, Analysis and classification of cardiac arrhythmia based on general sparsed neural network of ECG signals, *SN Appl. Sci.* 2 (2020) 1244.
- C.Che,ConstrainedtransformernetworkforECGsignalprocessingandarrhythmia classification, *BMC Med. Inform. Decis. Sci. Making* 21 (2021) 184.

Referencias

- Ang, K. K., Chin, Z. Y., Zhang, H., & Guan, C. (2008, June). Filter bank common spatial pattern (FBCSP) in brain-computer interface. In 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence) (pp. 2390-2397). IEEE.
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering*, 16(5), 051001.
- Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001.
- Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggenberger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420.
- Golmohammadi, M., Harati Nejad Torbati, A. H., Lopez de Diego, S., Obeid, I., & Picone, J. (2019). Automatic analysis of EEGs using big data and hybrid deep learning architectures. *Frontiers in human neuroscience*, 13, 76.
- Biswal, S., Kulas, J., Sun, H., Goparaju, B., Westover, M. B., Bianchi, M. T., & Sun, J. (2017). SLEEPNET: automated sleep staging system via deep learning. *arXiv preprint arXiv:1707.08262*.
- Obeid, I., & Picone, J. (2016). The temple university hospital EEG data corpus. *Frontiers in neuroscience*, 10, 196.
- Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., ... & Patras, I. (2011). Deap: A database for emotion analysis; using physiological signals. *IEEE transactions on affective computing*, 3(1), 18-31.
- Li, X., Zhao, Z., Song, D., Zhang, Y., Pan, J., Wu, L., ... & Wang, D. (2020). Latent Factor Decoding of Multi-Channel EEG for Emotion Recognition Through Autoencoder-Like Neural Networks. *Frontiers in Neuroscience*, 14, 87.
- López-Larraz, E., Ibáñez, J., Trincado-Alonso, F., Monge-Pereira, E., Pons, J. L., & Montesano, L. (2018). Comparing recalibration strategies for electroencephalography-based decoders of movement intention in neurological patients with motor disability. *International journal of neural systems*, 28(07), 1750060.
- Hartmann, K. G., Schirrmester, R. T., & Ball, T. (2018). EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals. *arXiv preprint arXiv:1806.01875*.

Navarra
Artificial Intelligence
Research

NAIR
CENTER

www.naircenter.com