
This is the **published version** of the bachelor thesis:

Bajja Sánchez, Omar; Hernandez Sabate, Aura, dir. Predicció de convulsions en pacients amb epilèpsia a partir dels seus senyals d'EEG. 2022. (Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/280734>

under the terms of the  license

Predicció de convulsions en pacients amb epilèpsia a partir dels seus senyals d'EEG

Omar Bajjà Sánchez

Resum– En aquest estudi s'utilitza una xarxa neuronal U-Net 2D juntament amb un classificador K-means per predir les convulsions en pacients amb epilèpsia a partir dels seus senyals d'electroencefalograma. La arquitectura U-Net es fa servir per tasques de segmentació biomèdica, però en aquest estudi s'adapta al domini temporal dels senyals de l'electroencefalograma per capturar patrons espacials i temporals associats a l'activitat elèctrica convulsiva.

Paraules clau– U-Net, *K-means*, EEG, *autoencoder*, convulsions, epilèpsia, CNN

Abstract– In this study, a 2D U-Net neural network, along with a K-means classifier, is used to predict seizures in patients with epilepsy using their electroencephalogram signals. The U-Net architecture is commonly used for biomedical segmentation tasks, but in this study, it is adapted to the temporal domain of electroencephalogram signals to capture spatial and temporal patterns associated with seizure activity.

Keywords– U-Net, K-means, EEG, autoencoder, seizures, epilepsy, CNN



1 INTRODUCCIÓ - CONTEXT DEL TREBALL

L'epilèpsia és una malaltia en què l'activitat elèctrica normal del cervell s'altera ocasionant convulsions, pèrdua de consciència i altres conseqüències neurobiològiques, cognitives, psicològiques i socials [1]. Les causes són molt variades: traumatismes, infeccions, tumors cerebrals o trastorns genètics, entre d'altres. A més, aquesta patologia pot afectar persones de totes les edats [2].

Les convulsions són el principal símptoma de l'epilèpsia. Es classifiquen segons si afecten tot el cervell (generalitzades) o només una àrea en concret (focals). En general, s'autolimiten en el temps, però en alguns casos es poden allargar i tenir conseqüències secundàries a llarg termini amb dany neuronal [3] [2] [4].

En alguns casos, la malaltia es pot controlar amb fàrmacs. No obstant això, en determinats pacients la medicació no és suficient i es fa necessari buscar altres estratègies. En aquest sentit, la detecció i la prevenció de les convulsions es fan crucials per als professionals de la salut.

L'electroencefalograma (EEG) és l'eina diagnòstica més important en les epilèpsies, ja que permet monitoritzar l'activitat cerebral mitjançant elèctrodes situats al voltant del crani. En el cas de l'epilèpsia, permet distingir quatre fases:

ictal, preictal, postictal i interictal. L'ús de les xarxes neuronals s'ha convertit en una prometedora línia de recerca per ajudar a predir aquests episodis en pacients amb epilèpsia gràcies a la identificació d'aquestes quatre fases.

En aquest article es presenta l'ús d'una xarxa neuronal de tipus U-Net 2D per detectar anomalies en els patrons normals. Al mateix temps s'utilitza juntament amb un classificador *K-means* analitzar la capacitat de la xarxa de predir les convulsions en pacients amb epilèpsia. S'analitzen els resultats obtinguts i es discuteix la seva utilitat en la prevenció i la detecció de la malaltia.

2 ESTAT DE L'ART

En els últims anys, la recerca en tècniques de predicció de crisis convulsives en epilèpsia ha concentrat una atenció considerable. En el passat, aquesta tasca s'havia realitzat partint de tècniques clàssiques de *Machine Learning* (ML). Per exemple, a partir dels *Support Vector Machine* (SVM) i altres tècniques, Ly V. Tran *et al.* [5] extreuen les característiques més rellevants del seu *dataset* (mínim, màxim, mitjana, mediana, desviació estàndard, variança, error quadràtic, curtosi i asimetria dels coeficients d'ondeta obtinguts del *Dirichlet wave transform* de l'EEG), comparen diferents tècniques de ML clàssic i obtenen un 98,4% amb un SVM, un 97,6% amb un *K-nearest neighbour* (K-NN), un 96,8% amb un *decision tree* i un 96,8% amb un *random forest*. Últimament, però, s'està optant pel *Deep Learning* (DL), que explora la predicció de convulsions a partir de les *convolutional neural network* (CNN) i les *Long*

- E-mail de contacte: obajja@gmail.com
- Menció realitzada: Computació
- Treball tutoritzat per: Aura Hernández
- Curs 2022/23

Short-Term Memory (LSTM). H. Takashi *et al.* [6] proposen dos models per predir convulsions. En el primer fan servir una CNN per processar EEGs com a imatges i obtenen un 4% de precisió i un 75% de sensibilitat. En el segon implementen un *autoencoder* específic a partir de l'EEG de cada pacient i obtenen un 8% de precisió i un 65% de sensibilitat. Sanguk Ryu *et al.* [7] fan servir una DenseNet amb una arquitectura LSTM. En els seus experiments consideren dues fases: en la primera processen el senyal produït per l'EEG i en la segona prediuen les convulsions a partir d'un entrenament amb el qual han ensenyat al model a diferenciar entre els estats interictal i preictal. Mitjançant aquesta proposta, obtenen una precisió d'un 93,28%. Gözutök *et al.* [8] obtenen una precisió del 92,2% en el seu estudi *Epileptic Seizure Prediction Using Convolutional Autoencoder Based Deep Learning*, on extreuen característiques a partir d'un *autoencoder* entrenat de forma no supervisada i desenvolupen un predictor de convulsions *end-to-end*. En l'àmbit de les xarxes neuronals es planteja un repte colateral: com es combinen els senyals [9].

3 OBJECTIUS

L'objectiu principal d'aquest projecte és predir convulsions en pacients amb epilèpsia a partir dels senyals d'EEG. El treball s'estructura en dues parts:

- Desenvolupament d'un *autoencoder*, una xarxa neuronal que s'utilitza per reconstruir imatges i, per tant, és capaç de reduir la dimensionalitat dels EEGs. Aquest *autoencoder* està implementat amb una xarxa convolucional U-Net 2D.
- Implementació d'un *K-means*, sobre les característiques extretes, que determini fins a quin punt es pot diferenciar en quina de les quatre fases es troba el senyal (ictal, interictal, preictal, postictal)

4 METODOLOGIA

Les xarxes U-Net 2D són *autoencoders* dedicats a la visió per computador, més concretament a resoldre problemes de segmentació semàntica, és a dir, a etiquetar cada píxel d'una imatge amb la classe representada. En aquest treball aquestes xarxes aprenen a reconstruir finestres interictals i, d'aquesta manera, mitjançant l'error de reconstrucció, es poden detectar finestres ictals.

L'arquitectura original d'aquest model s'il·lustra a la figura 1. El seu nom prové de la seva forma: una U. El model consisteix en una via de codificació (meitat esquerra) i una via de descodificació (meitat dreta). La codificació està conformada per una sèrie de blocs de dues convolucions de 3x3 seguides d'un *max pooling* de 2x2 que divideix la mida de la imatge a la meitat. La descodificació està conformada per una sèrie de blocs *up-convolution* de 2x2 que duplica la mida de la imatge, seguida de dues convolucions de 3x3[10]. La codificació i la descodificació estan unides per les connexions de salt, uns curtcircuits que passen informació de la meitat dreta a la meitat esquerra.

La implementació de la xarxa U-Net original requereix d'uns *inputs* amb un format concret a l'hora de fer els *max pooling* (imatges de 512x512). Originalment, les dades no

són imatges i, per tant, cal generar-les. Concretament generem imatges a partir dels 21 senyals corresponents als 21 elèctrodes de l'EEG tallats en finestres d'un segon i, a la implementació s'han canviat els *max pooling* i les convolucions a 4x1 per ajustar les dimensions.

Finalment, també es desenvolupa un *k-means* per classificar a partir de l'extracció de característiques que es realitza en la part de codificació de la xarxa.

5 DISSENY EXPERIMENTAL

5.1 Dades

Les dades utilitzades són registres de 24 pacients i estan extretes de la base de dades CHB-MIT Epilepsy [11] [12]. Cada registre és d'un únic subjecte i està etiquetat en algun moment amb, almenys, un episodi de convulsions. Els registres estan dividits en diferents fitxers *normal* i *seizure*. Els *normal* no contenen cap episodi de convulsió, mentre que els *seizure* en contenen almenys un. Aquesta divisió garanteix que no hi hagi contaminació per part de les dades preictals i postictals en l'entrenament, perquè només s'ha entrenat amb fitxers *normal*. Al mateix temps hem generat dues classes extra, just abans i després de cada convulsió. Així doncs, les finestres preictals i postictals són la unió de 5 finestres d'un segon abans i després d'un episodi de convulsions. Els registres tenen 21 senyals corresponents als diferents elèctrodes i estan enregistrats a 128 Hz, que corresponen a un segon d'activitat cerebral. A la figura 2 hi ha representats els 21 senyals de l'electroencefalograma del pacient chb01. Les dades estan etiquetades segons si el registre és interictal, ictal preictal o postictal. La distribució de les dades en funció de les classes es mostra a la figura 3.




Fig. 3: Distribució de les dades en funció de les classes.

En l'experimentació s'ha fet servir una U-Net 2D i, per tant, les dades s'han gestionat com si fossin imatges. Com hem dit abans, per aconseguir-ho es consideren finestres de 128 registres x 21 senyals (un segon d'activitat cerebral), que conformen una matriu i es fan servir d'imatge (amb un únic canal) com a entrada per a la xarxa.




Fig. 1: Arquitectura d'una U-Net 2D.




Fig. 2: 21 senyals del pacient chb01.

5.2 Disseny dels experiments

L'objectiu és ensenyar l'*autoencoder* a reconstruir finestres de registres interictals i tenir un model capaç de mesurar, mitjançant el càlcul de l'error per mínims quadràtics (MSE), la distància de la imatge d'entrada original a la imatge de sortida, de manera que detecti patrons anormals. Per això hem seleccionat un conjunt de 8 pacients (chb01, chb02, chb03, chb05, chb06, chb07, chb08, chb09) per entrenar i validar el model. Concretament, el conjunt de dades d'entrenament està conformat pel 80% de registres dels fitxers *normal*, i el conjunt de dades de validació està conformat pel 20% restant i la totalitat de registres ictals dels fitxers *seizure* del mateix conjunt. En la validació volem comprovar si la reconstrucció de la imatge és més propera a l'original en les dades interictals o en les ictals; per al test hem utilitzat la resta de pacients (del pacient chb10 al pacient chb24). Com que les dades estan molt desbalancejades hem triat totes les finestres ictal i, de forma aleatòria, el mateix nombre de finestres interictal, proporcionalment a cada pacient.

Per a tots els experiments d'aquesta fase s'ha fet servir la mateixa configuració:

EPOCHS	100
BATCH SIZE	64
DEPTH	3
WINDOWS SIZE	21x128
CRITERION	MSELoss()
LEARNING RATE	0.00001

Per avaluar el mètode desenvolupat s'han utilitzat diferents mètriques i representacions de l'MSE obtingut:

- Distribució de l'MSE segons la classe. Es representa en gràfiques *boxplot*.
- MSE mig segons la classe. Es representa en taules que permeten comparar les classes d'un mateix pacient.
- Distribució de l'MSE en funció del temps. Es representa en una gràfica i es marquen els episodis ictals.

6 RESULTATS

6.1 Referència

Per establir una referència que ajudarà a entendre els altres experiments, s'ha provat el model amb una part de les dades utilitzades per entrenar-lo. L'histograma de l'MSE dels resultats es pot veure a la figura 4, que mostra una distribució semblant a la normal, el que concorda amb la intuïció amb una mitjana de 0.00185 i una desviació estàndard de 0.00384




Fig. 4: Histograma de l'MSE de les dades de referència.

6.2 Validació

Per provar el model s'ha fet servir el 20% de dades extretes dels fitxers *normal* i la totalitat de dades ictals extretes dels fitxers *seizure* dels mateixos pacients per entrenar.




Fig. 5: Histograma de l'MSE amb les dades de referència, interictals i ictals.

La figura 5 mostra la distribució de l'MSE segons la classe. Totes les distribucions semblen normals, ara bé, la informació que proporcionen aquestes gràfiques no és suficient per diferenciar si un element pertany a una classe o a una altra, perquè les distribucions estan molt solapades i les formes són similars, tot i que les variàncies d'aquestes distribucions són diferents. És per això que s'ha decidit utilitzar gràfiques que representen la dispersió de l'MSE de les imatges (figura 6) i gràfiques *boxplot* (figura 7) per aprofundir l'anàlisi.

Com es podia preveure, en la representació (figura 6) de les dades de referència i les dades de test interictals hi ha una acumulació d'imatges amb MSE proper a 0. Tanmateix, la representació de les dades ictals també té una concentració d'imatges amb MSE proper a 0. Això es pot donar per una classificació errònia del model, per un biaix en les





Fig. 6: MSE de les dades de referència, interictals i ictals.

dades o perquè les imatges no siguin ictals. Així i tot, s'observa que la distribució de les ictals té valors MSE molt més alts que semblen seguir un patró creixent-decreixent.

A la figura 7, que permet estudiar la distribució dels valors de l'MSE de les imatges de referència, interictals i ictals, s'observa que, als *boxplot*, totes les classes presenten una gran quantitat de valors atípics.

Fig. 7: *Boxplot* de l'MSE amb les dades de referència, interictals i ictals.

Per quantificar la capacitat del model per diferenciar entre finestres ictals i interictals s'utilitza un *k-means*, un mètode d'aprenentatge no supervisat a l'espai de característiques generat per la U-Net.

Com s'ha descrit abans, les xarxes U-Net estan conformades per un *encoder* i un *decoder*. En la codificació, la xarxa realitza una extracció de característiques. És l'espai de característiques generat per l'encoder on, mitjançant un *k-means* es realitza una classificació de les dades segons si són ictals o interictals. El *k-means* està configurat amb dos clústers: un per la classe ictal i l'altre per la interictal. S'han descartat les classes preictal i postictal per la manca de dades. El model del *k-means* ha estat entrenat i validat. Per l'entrenament s'han fet servir un 80% de les dades ictals i el mateix nombre de dades interictals. En la fase de validació s'ha fet servir el 20% restant. Els resultats obtinguts són els següents, on la classe positiva és la ictal:

	Pred. ictal	Pred. interictal
Act. ictal	451	145
Act. interictal	197	503

TAULA 1: MATRIU DE CONFUSIÓ AMB ELS RESULTATS DE LA VALIDACIÓ DEL *k-means*

D'aquesta forma obtenim els següents valors per les mesures de validació:

Accuracy	0.736
Precision	0.695
Recall	0.756
F1-Score	0.725

6.3 Test

Per testejar el model s'ha realitzat un test independent amb cada un dels pacients no inclosos a l'entrenament.

A la taula 2 es mostren les mitjanes de l'MSE de les diferents classes per cada pacient no inclòs a l'entrenament. La fila correspon als valors del conjunt de validació. La primera columna correspon a la mitjana i la desviació estàndard del conjunt de referència. Els pacients amb millors resultats són aquells que presenten més diferència entre la mitjana ictal i la mitjana interictal, perquè facilita l'establiment d'un llindar a partir del qual es puguin classificar les dades en funció d'aquesta mètrica. Destaquen els bons resultats dels pacients chb10 i chb19 i els mals resultats dels pacients chb15, chb16 i chb17.

A la taula 3 es mostren les mitges de l'MSE de les diferents classes per cada pacient no inclòs a l'entrenament, però en aquest cas s'han descartat els *outliers*. Es pot observar que el pacient chb16 té uns resultats bons, juntament amb el chb10 i el chb19. Els pacients chb15 i chb17 continuen presentant una diferència baixa entre la mitja ictal i la mitja interictal.

A les figures 8 i 9 s'observen les distribucions de l'MSE dels pacients chb10 i chb19 representades gràficament en gràfiques *boxplot*, respectivament. Les dades ictals tenen un MSE mig més alt que les dades interictals. És probable que en aquests casos es pugui establir un llindar que permeti classificar en interictals o ictals les imatges en funció de l'MSE.

Les figures 10, 11 i 12 corresponen, respectivament, a les

	Referència	Interictal	Ictal	Preictal	Postictal
Val. set	0.00185 +- 0.00384	0.02162 +- 0.02837	0.06995 +- 0.11102	0.01347 +- 0.01992	0.0208 +- 0.03017
10	0.00185 +- 0.00384	0.00071 +- 0.00024	0.05331 +- 0.05169	0.00588 +- 0.00425	0.01491 +- 0.02674
11	0.00185 +- 0.00384	0.00763 +- 0.01028	0.02519 +- 0.03952	0.01311 +- 0.01474	0.01712 +- 0.01101
12	0.00185 +- 0.00384	0.00170 +- 0.00105	0.00391 +- 0.00296	0.00214 +- 0.00144	0.00746 +- 0.01452
13	0.00185 +- 0.00384	0.01678 +- 0.00831	0.02369 +- 0.0405	0.02907 +- 0.06217	0.02903 +- 0.04083
14	0.00185 +- 0.00384	0.00276 +- 0.0092	0.00345 +- 0.00381	0.00158 +- 0.00083	0.00227 +- 0.0029
15	0.00185 +- 0.00384	0.00276 +- 0.0092	0.00265 +- 0.00395	0.00177 +- 0.00132	0.00255 +- 0.00268
16	0.00185 +- 0.00384	0.01083 +- 0.01018	0.0181 +- 0.01368	0.00701 +- 0.00591	0.01907 +- 0.01948
17	0.00185 +- 0.00384	0.01429 +- 0.00402	0.01864 +- 0.0236	0.01351 +- 0.012	0.0063 +- 0.00779
18	0.00185 +- 0.00384	0.00162 +- 0.00068	0.01069 +- 0.01063	0.00403 +- 0.00487	0.00575 +- 0.00755
19	0.00185 +- 0.00384	0.00052 +- 6e-05	0.17896 +- 0.19041	0.00124 +- 0.00048	0.01163 +- 0.01057
20	0.00185 +- 0.00384	0.0009 +- 0.00029	0.0133 +- 0.01297	0.00157 +- 0.00032	0.00535 +- 0.00531
21	0.00185 +- 0.00384	0.0011 +- 0.00034	0.0046 +- 0.00397	0.00389 +- 0.00291	0.00606 +- 0.00637
22	0.00185 +- 0.00384	0.0009 +- 0.00025	0.04965 +- 0.04588	0.01376 +- 0.01047	0.05556 +- 0.04156
23	0.00185 +- 0.00384	0.00264 +- 0.00621	0.02796 +- 0.02726	0.01695 +- 0.01456	0.01439 +- 0.02044
24	0.00185 +- 0.00384	0.044 +- 0.02624	0.03771 +- 0.03925	0.00827 +- 0.01228	0.01465 +- 0.02532

TAULA 2: MITGES DELS PACIENTS.

	Referència	Interictal	Ictal	Preictal	Postictal
Val. set	0.00162 +- 0.00118	0.01899 +- 0.02274	0.05604 +- 0.08031	0.01125 +- 0.01242	0.01757 +- 0.02341
10	0.00162 +- 0.00118	0.00069 +- 0.00019	0.05061 +- 0.04483	0.00546 +- 0.00354	0.01111 +- 0.01522
11	0.00162 +- 0.00118	0.00669 +- 0.00811	0.02113 +- 0.02705	0.01311 +- 0.01474	0.01712 +- 0.01101
12	0.00162 +- 0.00118	0.00158 +- 0.00049	0.00365 +- 0.00176	0.00200 +- 0.00079	0.00557 +- 0.00954
13	0.00162 +- 0.00118	0.01622 +- 0.00353	0.01805 +- 0.0282	0.01769 +- 0.0258	0.02282 +- 0.02741
14	0.00162 +- 0.00118	0.00165 +- 0.00265	0.00294 +- 0.00232	0.00149 +- 0.00066	0.0019 +- 0.00176
15	0.00162 +- 0.00118	0.00103 +- 0.00056	0.00239 +- 0.00166	0.00162 +- 0.00083	0.0022 +- 0.00174
16	0.00162 +- 0.00118	0.00972 +- 0.00794	0.01748 +- 0.01279	0.00701 +- 0.00591	0.01737 +- 0.01652
17	0.00162 +- 0.00118	0.0142 +- 0.00386	0.01571 +- 0.01657	0.01351 +- 0.012	0.00451 +- 0.00414
18	0.00162 +- 0.00118	0.00156 +- 0.00035	0.00972 +- 0.00846	0.00403 +- 0.00487	0.00575 +- 0.00755
19	0.00162 +- 0.00118	0.00052 +- 5e-05	0.17592 +- 0.18503	0.00124 +- 0.00048	0.01163 +- 0.01057
20	0.00162 +- 0.00118	0.00087 +- 0.00022	0.01235 +- 0.01128	0.00155 +- 0.00028	0.00463 +- 0.00287
21	0.00162 +- 0.00118	0.00108 +- 0.00029	0.0042 +- 0.00273	0.00389 +- 0.00291	0.00606 +- 0.00637
22	0.00162 +- 0.00118	0.00088 +- 0.00019	0.04514 +- 0.0363	0.01376 +- 0.01047	0.05556 +- 0.04156
23	0.00162 +- 0.00118	0.00196 +- 0.00248	0.02509 +- 0.02088	0.01505 +- 0.00956	0.01169 +- 0.01318
24	0.00162 +- 0.00118	0.04165 +- 0.0201	0.03532 +- 0.03457	0.00678 +- 0.00985	0.00944 +- 0.01167

TAULA 3: MITGES SENSE outliers DELS PACIENTS

distribucions de l'MSE dels pacients chb15, chb16 i chb17 representades en gràfiques *boxplot*. En els casos del pacient chb15 i el pacient chb17, hi ha un solapament absolut entre les distribucions interictals i ictals. En el cas del pacient chb16, el solapament és parcial. En qualsevol cas, no és evident l'existència d'un llindar per separar les imatges en classes en funció del seu MSE.

A les figures 13 i 14 es representen els MSE de totes les imatges dels pacients chb17 i chb19 respectivament. Aquestes imatges estan ordenades temporalment. Les imatges interictals apareixen de color blau. De color taronja, verd i vermell apareixen els episodis de convulsions. En el pacient chb17 (un pacient amb resultats no satisfactoris) no es veu un patró clar en les dades ictals. Per contra, en el pacient chb19, els episodis ictals estan clarament representats per les zones amb acumulacions d'MSE més elevat. Hi ha un patró creixent quan comença la crisi.

7 CONCLUSIONS

En aquest treball s'ha adaptat una xarxa U-Net per detectar convulsions en pacients amb epilèpsia a partir dels seus senyals d'EEG. Per aconseguir-ho s'han considerat els senyals de l'EEG com imatges de 128 x 21. S'ha seguit la següent estratègia: l'entrenament s'ha realitzat amb dades interictals, de manera que els models implementats han après a reconstruir senyals normals. D'aquesta manera, quan les imatges són ictals, la reconstrucció és pitjor i l'MSE de l'*output* respecte de l'*input* és, en general, major. Per als entrenaments dels models no ha estat necessari fer servir més de 70 èpoques en cap cas.

També s'ha implementat un *K-means* que classifica les imatges segons si són ictals o interictals a partir de l'extracció de característiques que realitza la codificació de la imatge.

En l'estudi de l'MSE s'han obtingut resultats satisfactoris en alguns pacients (chb10, chb19) i resultats no satisfacto-




Fig. 8: *Boxplot* de les distribucions de l'MSE del pacient 10 per classes.




Fig. 11: *Boxplot* de les distribucions de l'MSE del pacient 16 per classes.




Fig. 9: *Boxplot* de les distribucions de l'MSE del pacient 19 per classes.




Fig. 12: *Boxplot* de les distribucions de l'MSE del pacient 17 per classes.




Fig. 10: *Boxplot* de les distribucions de l'MSE del pacient 15 per classes.

ris en altres pacients (chb15, chb17). Així i tot, els resultats són, en general acceptables. En el cas dels pacients que ob-

tenen millors resultats, les distribucions de l'MSE en funció del temps mostren uns patrons on la tendència és creixent amb pics molt superiors a l'MSE de les altres imatges. En el cas dels pacients amb pitjors resultats, l'MSE de les dades ictals queda camuflat entre les altres dades.

7.1 Treball futur

Per validar els experiments s'hauria de valorar l'aplicació d'una tècnica com un *leave-one-out* o un *k-fold*. En funció del nivell de generalització que es vulgui avaluar.

Per reconèixer crisis convulsives en epilèpsia amb la màxima precisió i rapidesa, una possible línia de recerca seria estudiar els patrons obtinguts a l'MSE a partir de d'*smoothing techniques for time series data*.

La configuració de la implementació pròpia utilitza convolucions i *max poolings* de 4x1. Aquesta configuració fa que l'estudi dels senyals sigui independent. Una possible línia de recerca consistiria en canviar els *max poolings* i les convolucions a una altra dimensió que consideri diferents senyals (4x4, per exemple) i així veure com canvien els resultats en funció de les combinacions de senyals. Una altra




Fig. 13: Representació dels MSE en funció del temps pel pacient 17. En aquest cas és complicat distingir els episodis convulsius (marcats amb color taronja, verd i vermell) de forma visual.




Fig. 14: Representació dels MSE en funció del temps pel pacient 19. En aquest cas és fàcil distingir els episodis convulsius (marcats amb color taronja, verd i vermell) de forma visual.

possible alternativa seria crear les imatges a partir d'una altra combinació de senyals (per exemple, en comptes de E8, F8,... podem posar F8, E8,...).

AGRAÏMENTS

A Aura Hernández per la tutorització del treball i a la meua família pel seu suport incondicional.

REFERÈNCIES

- [1] Robert S Fisher, Carlos Acevedo, Alexis Arzimanoglou, Alicia Bogacz, Helen Cross, Christian E Elger, Jerome Engel Jr, Lars Forsgren, Jacqueline A French, Mike Glynn, et al. Definición clínica práctica de la epilepsia. *Epilepsia*, 55(4):475–482, 2014.
- [2] Jessica Falco-Walter. Epilepsy—definition, classification, pathophysiology, and epidemiology. In *Seminars in neurology*, volume 40, pages 617–623. Thieme Medical Publishers, Inc., 2020.
- [3] DOCUMENTO DE POSICIÓN DE LA ILAE. Clasificación de las epilepsias de la ilae: Documento de posición de la comisión de clasificación y terminología de la ilae. *Epilepsia*, 58(4):512–521, 2017.
- [4] Robert S Fisher, HJ Cross, Jacqueline A French, Norimichi Higurashi, Edouard Hirsch, Floor E Jansen, Li-even Lagae, S Moshe, Jukka Peltola, E Roulet, et al. Clasificación operacional de los tipos de crisis por la liga internacional contra la epilepsia: Documento-

posición de la comisión para clasificación y terminología de la ilae. *Epilepsia*, 58(4):522–530, 2017.

- [5] Ly V Tran, Hieu M Tran, Tuan M Le, Tri TM Huynh, Hung T Tran, and Son VT Dao. Application of machine learning in epileptic seizure detection. *Diagnostics*, 12(11):2879, 2022.
- [6] Hirokazu Takahashi, Ali Emami, Takashi Shinozaki, Naoto Kunii, Takeshi Matsuo, and Kensuke Kawai. Convolutional neural network with autoencoder-assisted multiclass labelling for seizure detection based on scalp electroencephalography. *Computers in biology and medicine*, 125:104016, 10 2020.
- [7] Sanguk Ryu and Inwhee Joe. A hybrid densenet-lstm model for epileptic seizure prediction. *Applied Sciences*, 11(16), 2021.
- [8] Burak Gözütok and Ahmet Ademoğlu. Epileptic seizure prediction using convolutional autoencoder based deep learning. In *2021 29th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4, 2021.
- [9] Aura Hernández-Sabaté, José Yauri, Pau Folch, Miquel Àngel Piera, and Debora Gil. Recognition of the mental workloads of pilots in the cockpit using eeg signals. *Applied Sciences*, 12(5), 2022.
- [10] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.
- [11] Ali H. Shoeb and John V. Guttag. Application of machine learning to epileptic seizure detection. In *International Conference on Machine Learning*, 2010.
- [12] Ary L. Goldberger, Luis A. Nunes Amaral, L Glass, Jeffrey M. Hausdorff, Plamen Ch. Ivanov, Roger G. Mark, Joseph E. Mietus, George B. Moody, Chung-Kang Peng, and Harry Eugene Stanley. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *Circulation*, 101 23:E215–20, 2000.