

INFORME DEL PROYECTO REF.SV-24-GIJÓN-1-05

EEGANNomaly. Redes Generativas-Adversarias y Detección de Anomalías en registros EEG para la detección de respuestas foto-paroxísticas

Fechas inicial y final del proyecto:

01 / 06 / 2024 al 31 / 12 / 2024

Investigador/a Principal:

José Ramón Villar Flecha

Otros investigadores:

Fernando Moncada Martins

Personal contratado:

Marcos Ornia Luna

Fechas inicial y final de contratación:

01 / 09 / 2024 al 31 / 12 / 2024

Empresas o instituciones colaboradoras:

Hospital de Cabueñes (SESPA), y el Hospital Universitario de Burgos (SACYL).

Redes sociales de investigadores y empresas:

Pablo Calvo (pablo.calvo@sespa.es)

Beatriz García-López (bgarcialo@saludcastillayleon.es)

Resumen Gráfico




Figura 01. Resumen gráfico de EEGANNOMALY. Siguiendo el protocolo para diagnóstico de respuesta fotosensible definido en el sistema sanitario, se han obtenido dos resultados básicos: el diseño y obtención de modelos para la detección automática de este tipo de eventos y la captación de datos de pacientes sanos y afectados por este tipo de epilepsia. Imágenes generadas con IA.

Memoria descriptiva del proyecto

1. Resumen ejecutivo

EEGANNomaly está centrado en la detección de anomalías como resultado de respuestas fotoparoxísticas -un tipo de epilepsia- en registros electroencefalogramas (EEG). El alto coste de los análisis realizados por parte de los expertos neurofisiólogos que estudian los registros de EEG tomados a los pacientes para el diagnóstico de la fotosensibilidad paroxística es la razón fundamental que justifica el desarrollo de este proyecto.

El protocolo actual estandarizado exige estimular mediante secuencias de intermitencia luminosa a diferentes frecuencias a pacientes que potencialmente pueden ser epilépticos y que, consecuentemente, presentan unos registros EEG de alta actividad y excitación. Discriminar entre una situación normal o un posible evento PPR requiere una concentración y focalización tal que resulta extenuante; la no identificación de un evento PPR podría significar un ataque epiléptico en el paciente si no se detiene el protocolo de diagnóstico. Disponer de una herramienta que asesore en la decisión resulta primordial y de alto interés científico para los expertos neurofisiólogos.

Debido a la alta tasa de desbalanceo del conjunto de datos que se puede disponer, se estudiará igualmente el uso de redes neuronales generativas para disponer de datos sintéticos realísticos para aumentar el rendimiento del entrenamiento de los modelos de detección.

El desarrollo del proyecto está dividido en tres grandes apartados: i) **actualización del estado del arte**, especialmente en la detección de anomalías y en los modelos generativos para series temporales multivariable; ii) **aumento del conjunto de datos tomados en pruebas reales con pacientes anonimizados**, pruebas a realizar en los hospitales de Cabueñes y de Burgos; y iii) **desarrollo de propuestas innovadoras para la detección de anomalías** en el contexto de este proyecto, incluyendo definición de las experimentaciones a realizar.

Los objetivos de **EEGANNomaly** incluyen i) **Generar un estado del arte** actualizado en la detección de anomalías en registros EEG, especialmente centrados en algoritmos no supervisados y GANN, ii) **Seleccionar las propuestas** más relevantes en este contexto, adaptándolas al problema de detección de PPR, iii) **Realizar pruebas de validación** con datos reales, iv) **Publicar los resultados** en revistas indexadas y congresos internacionales, v) En los casos en que sea posible se procederá a la **protección de la propiedad intelectual** generada de la forma más adecuada en cada caso (patentes, modelos de utilidad, registros de propiedad intelectual, etc).

La metodología desarrollada incluyó las siguientes etapas: i) Actualización del estado del arte, tanto en detección de anomalías como en redes generativas aplicables en el contexto; ii) Definición de los conjuntos de datos disponibles para la experimentación; iii) Definición de las arquitecturas apropiadas para la detección de anomalías y definir el empleo de GANN; iv) Definición de la experimentación a realizar; y v) Extracción de conclusiones de esta investigación.

Los resultados obtenidos permitieron concluir que i) las redes basadas en autoencoder variacional para series temporales generan los mejores resultados, ii) que estos resultados están adaptados al paciente actual, asumiendo de esta manera las diferencias en comportamiento de las señales EEG, iii) los sistemas de detección de anomalías con modelos clásicos no supervisados no presentan resultados alentadores, iv) las redes inception pueden también generar resultados competitivos cuando se entrenan con suficientes datos, y v) es necesario disponer resultados con pacientes sanos.

Estos resultados han sido publicados en dos artículos de revistas con impacto JCR (uno de ellos en la fase final de evaluación) y un artículo de congreso que tendrá lugar en 2025, lo cual es una garantía clara de la calidad de la investigación realizada.

2. Objetivos iniciales del proyecto y grado de consecución

Tipo	Objetivo	Comentario	Grado de consecución
Principal	Obtener un algoritmo de detección de anomalías en registros EEG utilizando GANN y partiendo tanto de conjuntos de datos públicos como de datos reales obtenidos de sesiones de diagnósticos de PPR	No se llegó a implementar redes GANN	85%

Secundario/ Específico	Generar un estado del arte actualizado en la detección de anomalías en registros EEG, especialmente centrados en algoritmos no supervisados y GANN		100
Secundario/ Específico	Seleccionar las propuestas más relevantes en este contexto, adaptándolas al problema de detección de respuesta fotoparoxística.		100
Secundario/ Específico	Realizar pruebas de validación con datos reales		100
Secundario/ Específico	Publicar los resultados en revistas indexadas y congresos internacionales		100
Secundario/ Específico	En los casos en que sea posible se procederá a la protección de la propiedad intelectual generada de la forma más adecuada en cada caso.	No procede	-

3. Tareas realizadas:

ID	Descripción	MESES					
		1	2	3	4	5	6
Fase 1	Actualización del estado del arte						
Tarea 1.1	Actualización del estado del arte en la detección de PPR en registros EEG provenientes de IPS						
Tarea 1.2	Análisis del estado del arte en algoritmos personalizados para la detección de anomalías						
Tarea 1.3	Elaboración del estado del arte en algoritmos no supervisados y GANNS para la detección de anomalías en registros EEG						
Fase 2	Diseño de experimento						
Tarea 2.1	Selección de algoritmos y arquitecturas no supervisados para la detección de anomalías en EEG						
Tarea 2.2	Definición de los conjuntos de datos a utilizar						
Tarea 2.3	Definición de la experimentación y validación de hipótesis						
Fase 3	Implementación, pruebas y conclusiones						
Tarea 3.1	Implementación de algoritmos y arquitecturas						
Tarea 3.2	Ejecución de las pruebas experimentales y de validación						

Tarea 3.3	Extracción de conclusiones						
Tarea 3.4	Publicación de resultados						

Figura 02. Planificación del proyecto

4. Resultados obtenidos:

EEGANNomaly ha generado los siguientes resultados:

- Diseño de un modelo basado en autoencoder variacional para la detección de anomalías en señales EEG adaptadas para el contexto de epilepsia por respuesta fotosensible.




Figura 03. Comparativa de métodos de detección de anomalías, tanto basados en autoencoders variacionales como en otros métodos clásicos de detección de anomalías. Extraída del artículo en Logic Journal of the IGPL.




Figura 04. Red recursiva implementando el autoencoder variacional. Extraída del artículo Logic Journal of the IGPL

- Diseño de un modelo basado en redes neuronales tipo inception para la clasificación de ventanas de señales de EEG como provenientes de respuesta fotosensible o como normales.




Figura 05. Redes inception para la clasificación de series temporales como provenientes de ventana normal o fotoparoxística. Extraída del artículo en MLST.

- Aplicación de modelos de detección de anomalías no supervisados al problema, con resultados poco competitivos.




Figura 06. Comparativa de autoencoder variacional versus resto de modelos no supervisados clásicos de detección de anomalías. Extraída del artículo en Logic Journal of the IGPL.

- Captación de datos de pacientes sanos y afectados por este tipo de epilepsia, tanto en el Hospital de Cabueñes como en el Hospital de Burgos.

5. Trabajos o necesidades futuras

En un futuro, las propuestas realizadas deben compararse tanto con datos de pacientes que padecen de respuesta fotosensible como con datos de pacientes sanos. De esta

manera se puede valorar las posibilidades de aplicar estas propuestas de manera correcta, facilitando su integración como plug-in en el software de análisis de EEG comercial. Igualmente, es necesario evaluar el uso de GANN e inteligencia generativa para completar y mejorar el aprendizaje de los modelos.

6. Divulgación de los resultados

Los resultados de este proyecto han sido difundidos en las siguientes publicaciones.

Figura XX. Divulgación de los resultados.

Título	Autores	PTT	Congreso / Revista	Lugar y fecha
<i>Anomaly Detection Comparison for Photo-Paroxysmal Response Detection</i>	F. Moncada, Víctor M. González, José R. Villar, M. A. Gutiérrez, P. Calvo, S. Urdiales, R. Díaz, A- Dalla-Porta	Artículo en revista JCR	<i>Logic Journal of the IGPL</i>	Aceptado para publicación
<i>Inception networks, Data Augmentation and Transfer Learning in EEG-based photosensitivity diagnosis</i>	F. Moncada, Víctor M. González, José R. Villar, B. García-López, A. Gómez-Menéndez	Artículo en revista JCR	<i>Machine Learning: Science and Technology</i>	En evaluación
<i>Evaluation of an AI-EEG based Photo-Paroxysmal Response solution on healthy subjects: when false positive really matters</i>	M. Ornia, F. Moncada, Víctor M. González, José R. Villar, M. A. Gutiérrez, P. Calvo, S. Urdiales, R. Díaz, A- Dalla-Porta, B. García-López, A. Gómez-Menéndez	Com. Oral	<i>Olympiads of Engineering 2025</i>	Aceptado para publicación, Junio 2025
<i>Aplicación de IA y VR al análisis de EEGs para ayuda en el diagnóstico de fotosensibilidad</i>	José R. Villar	Com. Oral	<i>Desayunos Tecnológicos IUTA</i>	Gijón (Spain), Noviembre 2024

Figura 08. Divulgación de los resultados.

Memoria económica:

1. Gastos:

Concepto	Gasto
Personal (IUTA)	3.000 €
Fungibles	0 €
Amortización	1.000 €
Otros (Desplazamientos, Inscripciones a Congresos, etc)	1.000 €
TOTAL GASTOS	5.000 €

2. Ingresos:

Entidad/Empresa financiadora Ref. Proyecto/Contrato	Concepto	Ingreso
IUTA	Ayuda IUTA: Contratación de personal	3.000 €
Otras entidades / empresas financiadoras		0 €
Financiación propia		2.000 €
TOTAL INGRESOS		5.000 €

Bibliografía:

- [1] Kasteleijn-Nolst Trenité D. G.: Photosensitivity in epilepsy. Electrophysiological and clinical correlates. 1989. Acta Neurologica Scandinavica Vol. no. 125, pp. 3–149
- [2] Fisher R. S., Acharya J. N., Baumer F. M., French J. A., Parisi P., Solodar J. H., Szaflarski J. P., Thio L. L., Tolchin B., Wilkins A. J., Kasteleijn-Nolst Trenité D. G.: Visually sensitive seizures: An updated review by the Epilepsy Foundation. 2002. Epilepsia Vol. no. 63(4), pp. 739–768
<https://doi.org/10.1111/epi.17175>
- [3] Kasteleijn-Nolst Trenité D. G., Binnie C. D., Harding G. F., Wilkins A.: Photic stimulation: Standardization of screening methods. 1999. Epilepsia Vol. no. 40(9), pp. 739–768.
<https://doi.org/10.1111/j.1528-1157.1999.tb00911.x>
- [4] Rubboli G., Parra J., Seri S., Takahashi T., Thomas P.: EEG Diagnostic Procedures and Special Investigations in the Assessment of Photosensitivity. 2004. Epilepsia Vol. no. 45, pp. 739–768.
<https://doi.org/10.1111/j.0013-9580.2004.451002.x>
- [5] Meritam Larsen P., Wüstenhagen S., Terney D., Gardella E., Alving J., Aurlien H., Beniczky S.: EEG Photoparoxysmal response and its characteristics in a large EEG database using the SCORE system. 2021. Clinical Neurophysiology Vol. no. 132(2), pp. 365–371.
<https://doi.org/10.1016/j.clinph.2020.10.029>
- [6] Waltz S., Christen H. J., Doose H.: The different patterns of the photoparoxysmal response- a genetic study. 1992. Electroencephalography and Clinical Neurophysiology Vol. no. 83(2),
[https://doi.org/10.1016/0013-4694\(92\)90027-F](https://doi.org/10.1016/0013-4694(92)90027-F)
- [7] Strigaro G., Gori B., Varrasi C., Fleetwood T., Cantello G., Cantello R.: Flash-evoked high-frequency EEG oscillations in photosensitive epilepsies. 2021. Epilepsy Research Vol. no. 172(5),
<https://doi.org/10.1016/j.eplepsyres.2021.106597>
- [8] Parra J., Lopes da Silva F., Stroink H., Kalitzin S.: Is colour modulation an independent factor in human visual photosensitivity?. 2007. Brain: a journal of neurology Vol. no. 130(07), pp. 1679–1689.
<https://doi.org/10.1093/brain/awm103>

- [9] Rathore C., Prakash S., Makwana P.: Prevalence of photoparoxysmal response in patients with epilepsy: Effect of the underlying syndrome and treatment status. 2020. *Seizure* Vol. no. 82, pp. 39–43. <https://doi.org/10.1016/j.seizure.2020.09.006>
- [10] Kalitzin S., Parra J., Velis D., Lopes da Silva F.: Enhancement of phase clustering in the EEG/MEG gamma frequency band anticipates transitions to paroxysmal epileptiform activity in epileptic patients with known visual sensitivity. 2002. *IEEE transactions on bio-medical engineering* Vol. no. 49(12), pp. 1279–1286. <https://doi.org/10.1109/TBME.2002.804593>
- [11] Moncada F., Martín S., González V. M., Álvarez V. M., García-López B., Gómez Menéndez A. I., Villar J. R.: Virtual reality and machine learning in the automatic photoparoxysmal response detection. 2022. *Neural Computing and Applications* <https://doi.org/10.1007/s00521-022-06940-z> 14
- [12] Moncada F., González V. M., García-López B., Álvarez V. M., Villar J. R.: A Comparison of Machine Learning Techniques for the Detection of Type-4 PhotoParoxysmal Responses in Electroencephalographic Signals. 2022. In *Proceedings of the Hybrid Artificial Intelligent Systems International Conference* pp. 3–13. https://doi.org/10.1007/978-3-031-15471-3_1
- [13] Moncada Martins F., González V. M., García-López B., Villar J. R.: Data Augmentation effects on Highly Imbalanced EEG Data sets for Automatic Detection of Photoparoxysmal Responses. 2023. *Sensors* Vol. no. 23(4), <https://doi.org/10.3390/s23042312>
- [14] Moncada Martins F., González V. M., Villar J. R., García-López B., Gómez Menéndez A. I.: Analysis of Frequency Bands in Electroencephalograms for Automatic Detection of Photoparoxysmal Responses. 2023. In *Proceedings of the Hybrid Artificial Intelligent Systems International Conference* https://doi.org/10.1007/978-3-031-40725-3_63
- [15] Moncada Martins F., González V. M., Villar J. R., Gutiérrez M. A., Calvo P., Urdiales S., Díaz R., Dalla-Porta A.: Anomaly Detection in Electroencephalograms for Photosensitivity Diagnosis. 2024. *Conference of the Spanish Association for Artificial Intelligence (CAEPIA)*
- [16] Han S., Hu X., Huang H., Jiang M., Zhao Y.: ADBench: Anomaly Detection Benchmark. 2022. <https://doi.org/10.48550/arXiv.2206.09426>
- [17] Jasper H. H. et al. International Federation of Clinical Neurophysiology: Report of the committee on methods of clinical examination in electroencephalography. 1958. *Electroencephalography and Clinical Neurophysiology* Vol. no. 10(2), [https://doi.org/10.1016/0013-4694\(58\)90053-1](https://doi.org/10.1016/0013-4694(58)90053-1)
- [18] You S., Hwan Cho B., Shon Y. M., Seo D. W., Kim I. Y.: Semi-supervised automatic seizure detection using personalized anomaly detecting variational autoencoder with behind-the-ear EEG. 2022. *Computer methods and programs in biomedicine* <https://doi.org/10.1016/j.cmpb.2021.106542>
- [19] Su Y., Zhao Y., Niu C., Liu R., Sun W., Pei D.: Robust Anomaly Detection for Multivariate Time Series through Stochastic Recurrent Neural Network. 2019. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* pp. 2828–2837. <https://doi.org/10.1145/3292500.3330672>

- [20] Rezende D., Mohamed S.: Variational Inference with Normalizing Flows. 2015. Proceedings Of The 32nd International Conference On Machine Learning Vol. no. 37, pp. 1530–1538.
<https://doi.org/10.48550/arXiv.1505.05770>
- [21] Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay E.: Scikit-learn: Machine Learning in Python. 2011. Journal Of Machine Learning Research Vol. no. 12(85), pp. 2825–2830.
- [22] Zhao Y., Nasrullah Z., Li Z.: PyOD: A Python Toolbox for Scalable Outlier Detection. 2019. Journal Of Machine Learning Research Vol. no. 20(96), pp. 1–7. <http://jmlr.org/papers/v20/19-011.html>
15
- [23] Tharindu F., Harshala G., Simon D., Sridha S., Clinton F.: Deep Learning for Medical Anomaly Detection– A Survey. 2021. ACM Comput. Surv. Vol. no. 54(7), <https://doi.org/10.1145/3464423>
- [24] Han, C., Rundo, L., Murao, K., Noguchi, T., Shimahara, Y., Milacski, Z., Koshino, S., Sala, E., Nakayama, H., Satoh, S.: MADGAN: unsupervised medical anomaly detection GAN using multiple adjacent brain MRI slice reconstruction. 2021. BMC Bioinformatics Vol. no. 22(2),
<https://doi.org/10.1186/s12859-020-03936-1>
- [25] Shvetsova, N., Bakker, B., Fedulova, I., Schulz, H., Dylov, D.: Anomaly Detection in Medical Imaging With Deep Perceptual Autoencoders. 2021. IEEE Access Vol. no. 9, pp. 118571–11858.
<https://doi.org/10.1109/ACCESS.2021.3107163>
- [26] Pilcevic, D., Djuric Jovicic, M., Antonijevic, M., Bacanin, N., Jovanovic, L., Zivkovic, M., Dragovic, M., Bisevac, P.: Performance evaluation of metaheuristics tuned recurrent neural networks for electroencephalography anomaly detection. 2023. Frontiers in Physiology Vol. no. 14,
<https://doi.org/10.3389/fphys.2023.1267011>
- [27] You S., Cho B. H., Yook S., Kim J. Y., Shon Y. M., Seo D. W., Kim I. Y.: Unsupervised automatic seizure detection for focal-onset seizures recorded with behind-the ear EEG using an anomaly-detecting generative adversarial network. 2020. Computer methods and programs in biomedicine
<https://doi.org/10.1016/j.cmpb.2020.105472>
- [28] Karpov, O., Khoymov, M., Maksimenko, V., Grubov, V., Utyashev, N., Andrikov, D., Kurkin, S., Hramov, A.: Evaluation of Unsupervised Anomaly Detection Techniques in Labelling Epileptic Seizures on Human EEG. 2023. Applied Sciences Vol. no. 13(9),
<https://doi.org/10.3390/app13095655>
- [29] Shyu, M., Chen, S., Sarinnapakorn, K., Chang, L.: A Novel Anomaly Detection Scheme Based on Principal Component Classifier. 2003. Proceedings of International Conference on Data Mining
- [30] Schölkopf, B., Williamson, R. C., Smola, A., Shawe-Taylor, J., Platt, J.: Support Vector Method for Novelty Detection. 1999. Advances in Neural Information Processing Systems Vol. no. 12,
- [31] Breunig, M. M., Kriegel, H., Ng, R. T., Sander, J.: LOF: identifying density-based local outliers. 2000. SIGMOD Vol. no. 29(2), pp. 93–104. <https://doi.org/10.1145/335191.335388>

- [32] He, Z., Xu, X., Deng, S.: Discovering cluster-based local outliers. 2003. Pattern Recogn. Lett. Vol. no. 24, pp. 1641–1650. [https://doi.org/10.1016/S0167-8655\(03\)00003-5](https://doi.org/10.1016/S0167-8655(03)00003-5)
- [33] Goldstein, M., Dengel, A.: Histogram-based Outlier Score (HBOS): A fast Unsupervised Anomaly Detection Algorithm. 2012. KI-2012
- [34] Ramaswamy, S., Rastogi, R., Shim, K.: Efficient algorithms for mining outliers from large data sets. 2000. SIGMOD Vol. no. 29(2), pp. 427–438. <https://doi.org/10.1145/335191.335437.16>
- [35] Kriegel, H., Kröger, P., Schubert, E., Zimek, A.: Outlier Detection in Axis-Parallel Subspaces of High Dimensional Data. 2009. Proc. PAKDD Vol. no. 5476, pp. 831–838 https://doi.org/10.1007/978-3-642-01307-2_86
- [36] Li, Z., Zhao, Y., Botta, N., Ionescu, C., Hu, X.: COPOD: Copula-Based Outlier Detection. 2020. 2020 IEEE International Conference on Data Mining (ICDM) pp. 1118–1123. <https://doi.org/10.1109/ICDM50108.2020.00135>
- [37] Li, Z., Zhao, Y., Hu, X., Botta, N., Ionescu, C., Chen, G. H.: ECOD: Unsupervised Outlier Detection Using Empirical Cumulative Distribution Functions. 2023. IEEE Transactions on Knowledge and Data Engineering Vol. no. 35(12), pp. 12181–12193. <https://doi.org/10.1109/TKDE.2022.3159580>
- [38] Zong, B., Song, Q., Min, M. R., Cheng, W., Lumezanu, C., Cho, D., Chen, H.: Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection. 2018. International Conference on Learning Representations
- [39] Pevný, T.: Loda: Lightweight on-line detector of anomalies. 2016. Machine Learning Vol. no. 102(2), pp. 275–304 <https://doi.org/10.1007/s10994-015-5521-0>
- [40] Liu, F. T., Ting, K. M., Zhou, Z.: Isolation Forest. 2008. 2008 Eighth IEEE International Conference on Data Mining Vol. no. (), pp. 413–422. <https://doi.org/10.1109/ICDM.2008.17>