

Jornadas de Automática

Deep Learning para asistencia en rehabilitación con robots mediante demostraciones

Martínez-Pascual, D.^{a,*}, Reig-Lozano, A.^a, Vales, Y.^a, Catalán, J.M..^a, Lledó, L. D.^a, García-Aracil, N.^a

^aGrupo de Robótica e Inteligencia Artificial, Instituto de Bioingeniería de Elche, Universidad Miguel Hernández,
Avenida de la Universidad, s/n. 03202 Elche, Alicante, España

To cite this article: Martínez-Pascual, D., Reig-Lozano, A., Vales, Y., Catalán, J.M., Lledó, L.D., García-Aracil, N. 2024. Deep Learning for robot-assisted rehabilitation by means of demonstrations. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10876>

Resumen

El uso de dispositivos robóticos de rehabilitación ha surgido como una solución prometedora para mejorar la recuperación motora durante la rehabilitación. Uno de los retos más significativos durante el uso de estos dispositivos es la capacidad de decidir cuándo proporcionar asistencia al paciente. En este contexto, se ha propuesto una solución basada en Deep Learning para aprender del criterio de un terapeuta cuándo un paciente necesita asistencia. Con el objetivo de desarrollar un modelo que permita generalizar a múltiples situaciones, se ha aplicado una serie de transformaciones a las trayectorias realizadas por los pacientes antes de utilizarlas como entradas al modelo. El modelo propuesto ha sido evaluado utilizando diferentes métricas y ha mostrado una precisión del 93,21 % y un F1-Score del 85,05 % con el conjunto de datos de validación. Además, el modelo ha alcanzado una precisión del 69,32 % y un F1-Score del 63,31 % con usuarios que no participaron en el proceso de aprendizaje del modelo.

Palabras clave: Tecnología de asistencia e ingeniería de rehabilitación, Ingeniería de rehabilitación y asistencia sanitaria, Toma de decisiones y procesos cognitivos, Automatización centrada en el ser humano, Interfaces inteligentes

Deep Learning for robot-assisted rehabilitation by means of demonstrations

Abstract

Robotic rehabilitation devices have shown promise in improving motor recovery. However, a significant challenge lies in determining when to provide assistance to the patient. To address this, a Deep Learning-based approach has been proposed to learn from a therapist's criteria in identifying when a patient requires assistance. In order to develop a model that can be generalized to multiple situations, a series of transformations have been applied to the trajectories performed by the patients before using them as inputs to the model. The performance of the model was evaluated using different metrics and achieved an accuracy of 93.21 % and an F1-Score of 85.05 % with the validation dataset. Furthermore, the model demonstrated an accuracy of 69.32 % and an F1-Score of 63.31 % with users who were not part of the learning process.

Keywords: Assitive technology and rehabilitation engineering, Rehabilitation engineering and healthcare delivery, Decision making and cognitive processes, Human centred automation, Intelligent interfaces

1. Introducción

Alrededor de 15 millones de personas en todo el mundo sufren accidentes cerebrovasculares cada año (Stevens et al., 2017). Además, se prevé que el número de ictus aumentará un 34 % para 2035 en la UE. Es común que los supervivientes

de un ictus sufran hemiparesia, lo que provoca un deterioro significativo de su calidad de vida. (van Peppen et al., 2004; Nichols-Larsen et al., 2005). En la mayoría de los casos, un programa de rehabilitación adecuado puede ayudar a las personas que sufren hemiparesia a recuperar el movimiento de las extremidades (Alessandro et al., 2020). En este contex-

*Autor para correspondencia: david.martinezp@umh.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

to, los dispositivos robóticos de rehabilitación han demostrado ser una solución prometedora para mejorar el proceso de rehabilitación motora tras sufrir un ictus. El principal objetivo de los dispositivos robóticos de rehabilitación es ayudar a los pacientes a realizar ejercicios diseñados para que la terapia resulte atractiva y divertida, con el fin de motivarles. Además, estos dispositivos pueden proporcionar una terapia estandarizada e intensiva, a la vez que proporcionan herramientas para evaluar el progreso de recuperación del paciente.

Algunos estudios sugieren que las interacciones robot-paciente tienen ventajas potenciales sobre las interacciones convencionales terapeuta-paciente en terapia ocupacional (Fong et al., 2020). Sin embargo, en la actualidad se desconocen los beneficios de las interacciones terapeuta-robot-paciente, ya que en la mayoría de las terapias asistidas por robots es el paciente quien interactúa solamente con el robot.

En la literatura se pueden encontrar varios métodos de asistencia empleados con diferentes dispositivos robóticos de rehabilitación, que difieren principalmente en la estrategia utilizada para proporcionar asistencia al usuario (Catalán et al., 2023; Blank et al., 2014). Sin embargo, ninguno de estos métodos implica la interacción del terapeuta. En un estudio anterior, se observó que un terapeuta determina mejor cuándo asistir al paciente que un método de asistencia fija implementado en un dispositivo robótico de rehabilitación (Catalán et al., 2021). Por tanto, puede decirse que la asistencia en tiempo real proporcionada por un terapeuta se adapta mejor a las necesidades de los pacientes, maximizando su esfuerzo y mejorando potencialmente la recuperación del paciente, los cuales son factores crítico en los resultados de la rehabilitación (Maclean et al., 2000; Friedrich et al., 1998).

En este trabajo se propone un nuevo enfoque de asistencia inteligente que permita adaptar mejor la asistencia provista por sistemas robóticos de rehabilitación a las necesidades de cada paciente. La estrategia propuesta consiste en desarrollar un método de asistencia basado en la toma de decisiones de los terapeutas. Con este objetivo, se ha entrenado y evaluado un modelo de Deep Learning utilizando datos recogidos en un estudio previo de nuestro grupo de investigación (Catalán et al., 2021). En dicho estudio, diferentes pacientes jugaban a alcanzar diferentes objetivos y un terapeuta les proporcionaba asistencia cuando lo consideraba necesario. Basándose en los movimientos realizados por un paciente, el modelo desarrollado clasifica si se necesita asistencia durante un ejercicio asistido por robot según el criterio del terapeuta.

2. Materiales y Métodos

2.1. Información sobre los pacientes

El estudio se ha realizado en el Hospital La Pedrera (Deña, España) con 8 pacientes que padecen afecciones neurológicas (Tabla 1). Los terapeutas rehabilitadores fueron los encargados de establecer los criterios de inclusión, que incluían: adultos con hemiparesia/hemiplejía, orientados a las tres esferas (social, temporal y espacial), con capacidad de colaboración y comprensión de la instrucción de tareas y de toda la información relevante del estudio. Se empleó la prueba STREAM para evaluar la coordinación, el movimiento voluntario funcional y la amplitud de movimiento del paciente (Ahmed et al., 2003). Sólo se tuvo en cuenta la puntuación obtenida en la extremidad superior.

El protocolo experimental fue aprobado por el Comité Ético del Hospital La Pedrera. Todos los pacientes fueron informados adecuadamente por el equipo de rehabilitación y los investigadores encargados de realizar la experimentación, y dieron su consentimiento por escrito antes de comenzar señalando que entendían la finalidad y los requisitos del estudio.

2.2. Equipos empleados y adquisición de datos

Los dispositivos empleados para la recogida de datos se muestran en la Figura 1. Tal y como se describe en (Catalán et al., 2021), en el estudio se empleó un dispositivo robótico de rehabilitación del miembro superior llamado Rubidium. Este sistema robótico está formado por un paralelogramo articulado accionado por dos motores eléctricos. El sistema permite realizar movimientos en un plano horizontal, y consta de una órtesis anclada al efector final que permite soportar el brazo del usuario.

El ejercicio realizado durante las sesiones experimentales está basado en una metodología punto a punto, donde los pacientes debían alcanzar un punto en la periferia de una ruleta desde su centro. Durante el transcurso del juego, se proponen diversos intentos. Para cada uno de los intentos el paciente parte del punto central y debe llegar al punto en la periferia marcado en rojo. En este estudio se utilizó una estrategia de asistencia en la que el dispositivo robótico de rehabilitación no proporciona asistencia, sino que la asistencia la proporciona el terapeuta interactuando directamente con el paciente. Para ello el terapeuta aplicó fuerza sobre el efector final del Rubidium, para lo cual se añadió al robot un sensor de fuerza onRobot HEX para registrar la asistencia (Figura 1.b). De este modo, puede medirse la fuerza ejercida por el terapeuta y el momento en que se presta la asistencia.

Tabla 1: Información acerca de los pacientes. Notas: N/A, valor no disponible; STREAM, *Stroke Rehabilitation Assessment of Movement*, el valor indica la puntuación obtenida para el miembro superior.

Pacientes	Sexo	Edad (años)	Diagnóstico	Lateralidad	STREAM
1	Varón	72	Distensión abdominal	Right	10/16
2	Varón	51	Hematoma ganglios basales	Right	11/16
3	Varón	70	SARS-CoV2 neumonía bilateral	Left	N/A
4	Varón	78	Ictus isquémico aterotrombótico	Right	11/16
5	Mujer	84	Ictus isquémico	Right	7/16
6	Varón	69	Ictus isquémico	Left	7/16
7	Varón	69	Ictus cápsulo-lacunar talámico	Right	0/16
8	Varón	62	Cardiopatía isquémica crónica	Right	8/16




Figura 1: Representación de los diferentes elementos involucrados en las sesiones experimentales. (a) Representación del juego planteado junto con el robot de rehabilitación Rubidium, el cual es comercializado y distribuido por la spin-off iDRhA (iDRhA, 2024). (b) Imagen de una sesión experimental

2.3. Procesamiento de datos

Se pretende que el método propuesto en este trabajo pueda ser utilizado durante diferentes juegos basados en la dinámica de alcanzar objetivos. Para ello, es necesario aplicar una serie de transformaciones a los datos adquiridos mediante el robot de rehabilitación Rubidium antes de su introducción como entradas al modelo de Deep Learning. El procesamiento aplicado se ha representado en la Figura 3.

En primer lugar, se ha tomado cada uno de los puntos de trayectoria P_r entre el punto inicial S_r y el punto objetivo G_r . A cada P_r se le ha aplicado la transformación ${}_rT^u$. Aplicando ${}_rT^u$ transformamos $S_r \rightarrow S_u = (0, 0)$ y P_r se alinea con el eje X. La transformación ${}_rT^u$ se expresa como:

$${}_rT^u = \begin{bmatrix} \cos(\theta_x) & -\sin(\theta_x) & 0 & -S_{r,x} \\ \sin(\theta_x) & \cos(\theta_x) & 0 & -S_{r,y} \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

donde θ_x es el ángulo del vector $\vec{P}G$ con el eje X. Aplicando ${}_rT^u$ podemos obtener la trayectoria realizada por el usuario P_a alineada con el eje X, así como el punto objetivo G_a situado sobre el eje X.

$$P_a = {}_rT^u \cdot P_r \quad (2)$$

$$G_a = {}_rT^u \cdot G_r \quad (3)$$

Por último, se ha aplicado un factor de escala a P_a en el

eje X para transformar $G_a \rightarrow G_u = (1, 0)$:

$$P_u = \begin{bmatrix} \frac{1}{G_{a,x}} & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot P_a \quad (4)$$

Una vez aplicadas las transformaciones, se ha calculado la distancia al objetivo d_u para cada muestra:

$$d_u = \|\overrightarrow{P_u G_u}\| \quad (5)$$

Para detectar la asistencia proporcionada por el terapeuta, se midió la fuerza F con el sensor colocado en el efector final del robot. Para cada P_u , si F es superior a 0,5N, la trayectoria se etiqueta como asistida. Por el contrario, se etiqueta como no asistida. Por tanto:

$$Y = \begin{cases} 0 & \text{if } F \leq 0,5 \\ 1 & \text{if } F > 0,5 \end{cases} \quad (6)$$

Para saber si el paciente necesita asistencia, se ha utilizado el conjunto de datos $\mathcal{D} : (x, y)$ para el entrenamiento del modelo, donde $x \in X = \{P_{u,x}, P_{u,y}, d_u\}$ es la entrada e $y \in Y$ es la salida. Como el problema se aborda como una clasificación de series temporales multivariantes, utilizamos como entrada un vector x_t que contiene los dos últimos segundos para predecir y_t . Los datos se adquieren del robot Rubidium a 30 Hz, por lo que x_t se compone de las últimas 60 muestras, $(x_{t-59}, x_{t-58}, \dots, x_{t-1}, x_t) \in X$.

Cabe destacar que sólo se introducen como entradas del modelo los datos obtenidos de los movimientos realizados por el paciente. Una vez detectada la asistencia, el movimiento realizado por el terapeuta para asistir al paciente se suprime de los datos de entrada. Por lo tanto, los datos contenidos en x_t durante el intento se etiquetan como trayectoria asistida antes de la intervención del terapeuta.

Antes del entrenamiento, \mathcal{D} se ha dividido en tres subconjuntos diferentes. Los datos de 6 usuarios se han utilizado como conjuntos de datos de entrenamiento y validación. El 80 % de los intentos asistidos y el 80 % de los intentos no asistidos se han utilizado para entrenar el modelo. El 20 % restante de los intentos asistidos y no asistidos se ha utilizado para la validación del modelo. Los datos de los otros 2 pacientes se han utilizado como conjunto de datos de test. Además, como las entradas $P_{u,x}, d_u \in (0, 1)$ debido a las transformaciones aplicadas, se ha escalado $P_{u,y}$ entre los valores mínimo y máximo del conjunto de datos de entrenamiento para que estén en un rango similar al de las otras entradas.

2.4. Arquitectura del modelo

Como se ha introducido, se plantea desarrollar un clasificador basado en un modelo de Deep Learning para aprender del terapeuta cuándo se debe asistir durante terapias de rehabilitación asistidas por robots. El problema se puede definir como el aprendizaje de una función de clasificación $\hat{y} = f(x_t)$, tal que $\hat{y}_t \approx y_t, \forall x_t \in X$.

En este trabajo se propone entrenar un modelo de Deep Learning basado en el Encoder propuesto por Serrà et al., cuya arquitectura está especialmente diseñada para la clasificación de series temporales (Serra et al., 2018). El modelo está

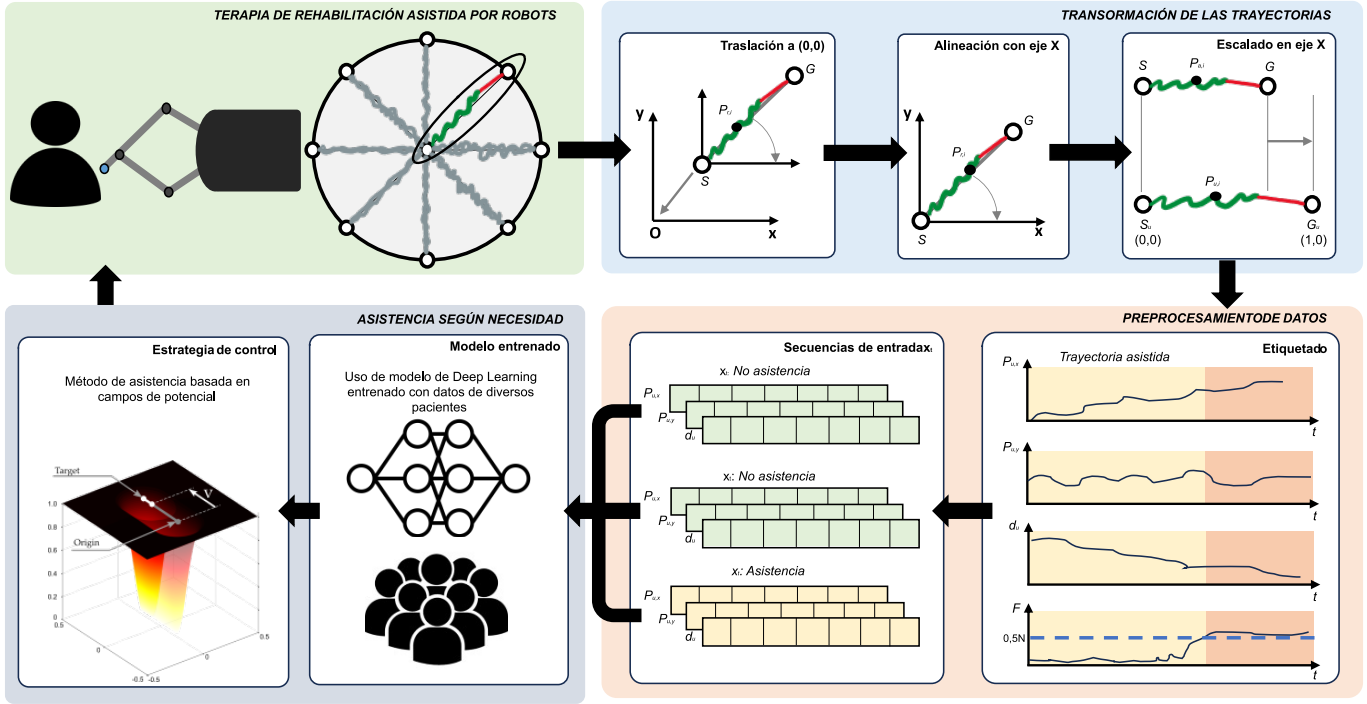


Figura 2: Estrategia propuesta de asistencia según necesidad durante una terapia asistida por un robot. El paciente realiza un movimiento y se adquieren las coordenadas cartesianas del efector final del robot. De acuerdo con el punto de partida S , y la posición objetivo G , la trayectoria se alinea con el eje X y se escala. Los datos recogidos mediante el sensor de fuerza incorporado en el efector final se emplean para etiquetar las trayectorias como asistidas o no asistidas. Las trayectorias se dividen en secuencias de dos segundos. Las secuencias se introducen como entradas en el modelo de Deep Learning, que aprende de las intervenciones del terapeuta y clasifica si el paciente necesita asistencia en función de los movimientos realizados.

compuesto por capas convolucionales unidimensionales, con un mecanismo de atención convolucional, y una capa final totalmente conectada.

La primera convolución se compone de 128 filtros de longitud 5; la segunda convolución se compone de 256 filtros de longitud 11; la tercera convolución se compone de 512 filtros de longitud 21. Cada convolución va seguida de una operación de normalización *instance normalization* (Ulyanov et al., 2016) cuya salida se introduce en la función de activación PReLU(He et al., 2015). A la salida de PReLU le sigue una operación de *dropout* (con una tasa igual a 0,2) y un *max-pooling* final de longitud 2. Después de estas capas, la mitad de los filtros se introducen en una activación softmax en función del tiempo, que actúa como mecanismo de atención (Niu et al., 2021) para la otra mitad de los filtros. El resultado del mecanismo de atención para todos los filtros se pasa finalmente a través de una capa totalmente conectada de 256 neuronas y una capa de *instance normalization*. Por último, se utiliza una capa con una neurona como salida del modelo. En las capas totalmente conectadas, se utilizó la función de activación Sigmoide (Pratiwi et al., 2020) para nuestro problema de clasificación binaria. El número total de parámetros entrenables del modelo es 3188865.

El modelo ha sido implementado y entrenado utilizando Keras y Tensorflow (Gulli and Pal, 2017), utilizando la función de coste *Binary Cross-Entropy* (Ruby and Yendapalli, 2020) y un tamaño de *batch* de 256. Para evitar el *overfitting*, se ha monitorizado el coste del conjunto de datos de validación, deteniendo el entrenamiento si el coste no mejoraba durante 5 *epochs*. Tras la parada anticipada, se restablecían los parámetros del modelo que obtenía el coste más bajo.

Tabla 2: Resultados de evaluación del modelo cuando se clasifica si la asistencia es necesaria durante terapias de rehabilitación asistidas con robots. Para evaluar el modelo se ha empleado la precisión, el *recall*, la especificidad, la tasa de falsos positivos, la tasa de falsos negativos, y el F1-Score.

Métrica	Entr.	Val.	Test
Precisión (%)	95.00	93.21	69.32
Recall (%)	88.93	76.81	58.65
Especificidad (%)	96.60	98.72	78.10
Tasa falsos positivos (%)	3.39	1.28	21.90
Tasa falsos negativos (%)	11.07	23.19	41.35
F1-Score (%)	88.12	85.05	63.31

3. Resultados y Discusión

La Tabla 2 recoge la precisión, el *recall*, la especificidad, la tasa de falsos positivos, la tasa de falsos negativos y el F1-Score al evaluar el modelo propuesto con los conjuntos de datos de entrenamiento, validación y test (Koyejo et al., 2014). En la Figura 4 se ha representado la curva *Receiver Operating Characteristic* (ROC) para los conjuntos de datos de validación y test, y se han incluido los valores del área bajo las curvas (AUC) (Flach, 2016). Además, las matrices de confusión para los conjuntos de datos de validación y de test se representan en la Figura 5.

Las métricas de evaluación muestran un alto rendimiento del modelo con pacientes implicados en el proceso de aprendizaje. Con el conjunto de datos de validación, el modelo alcanza una precisión del 93,21 %, una tasa de falsos positivos del 1,28 %, una tasa de falsos negativos del 11,07 % y un F1-Score del 85,05 %. En la Figura 4 también se puede observar como el modelo propuesto alcanza un alto rendimiento con el

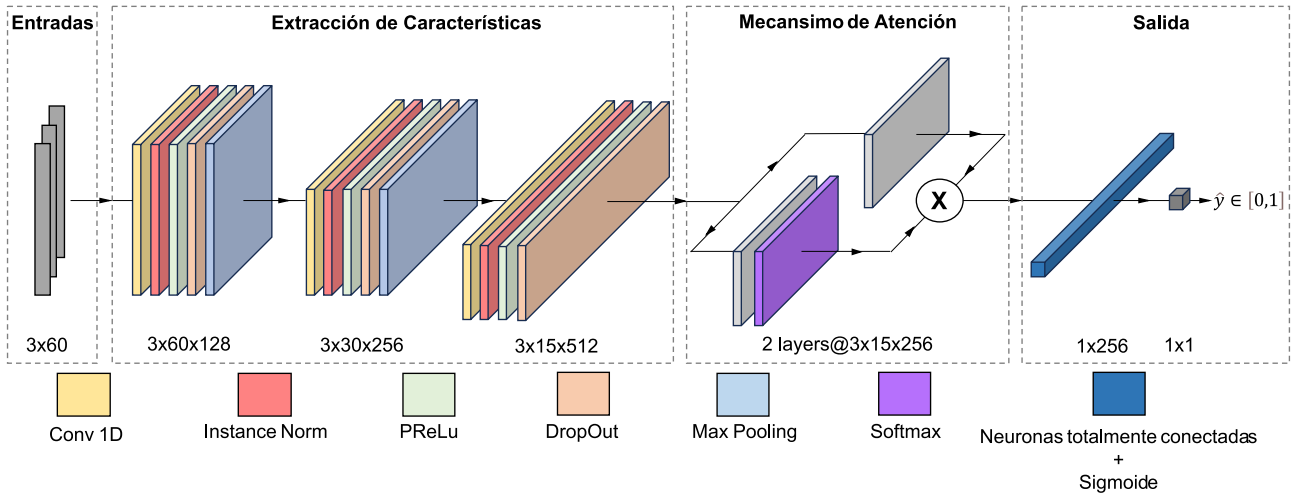


Figura 3: Arquitectura del modelo de Deep Learning propuesto para proporcionar asistencia según necesidad durante terapias de rehabilitación asistidas por robots. En primer lugar, a las secuencias de entrada se les aplican tres bloques convolucionales para realizar la extracción de características. Tras estas capas, la mitad de los filtros extraídos se utilizan como entradas de una activación softmax temporal, que actúa como mecanismo de atención para la otra mitad de los filtros. Por último, se utiliza una capa de neuronas totalmente conectadas y una neurona con la función de activación sigmoide para inferir si un paciente necesita asistencia en función de los movimientos realizados.

conjunto de datos de validación, con una curva ROC cercana al clasificador ideal, con un valor AUC de 0,97. Según la Figura 5, el modelo propuesto puede clasificar correctamente 2319 secuencias de trayectorias no asistidas y 606 secuencias de trayectorias asistidas. Cabe destacar que sólo 183 secuencias de trayectorias asistidas fueron clasificadas incorrectamente como no asistidas. Estos resultados pueden considerarse positivos, ya que algunas secuencias durante las trayectorias asistidas pueden estar alejadas de la intervención del terapeuta. Esto significa que ciertas secuencias pueden clasificarse como no asistidas, pero si el paciente no alcanza su objetivo, puede detectarse que necesita asistencia en un momento posterior. Además, el modelo ha identificado que el paciente sólo necesitaría asistencia en 30 secuencias durante las trayectorias no asistidas.

En cuanto a los resultados obtenidos con el conjunto de datos de test, se observa que el rendimiento del modelo propuesto disminuye con los pacientes que no participan en el entrenamiento del modelo. La precisión obtenida con estos pacientes es del 69 %, con una tasa de falsos positivos del 21,90 % y una tasa de falsos negativos del 41,35 %. Además, en la Figura 4 se puede observar cómo la curva ROC se aleja del clasificador ideal respecto a la obtenida con el conjunto de datos de validación, con un valor de AUC de 0,78. Según la matriz de confusión (Figura 5), es posible clasificar correctamente 4931 secuencias en las que el paciente no requiere asistencia y 3045 en las que requiere asistencia. Sin embargo, hay que tener especial cuidado con los 1383 falsos positivos, en los que se prestaría asistencia a pacientes que, según el criterio del terapeuta, no la necesitarían.

Aunque el rendimiento del modelo de clasificación de asistencia según necesidad ha mostrado un descenso con el conjunto de datos de test, creemos que este comportamiento puede atribuirse a la disparidad en los diagnósticos de los pacientes, como se indica en la Tabla 1. La variación en los diagnósticos, combinada con las diferentes capacidades motoras entre los pacientes, daría lugar a diferentes patrones de movimiento ejecutados por los pacientes. Además, hay que te-

ner en cuenta que el número de participantes en este estudio es bajo, por lo que se necesita un análisis más amplio y exhaustivo para confirmar esta hipótesis. Además, según (Alessandro et al., 2020) la personalización de la terapia de rehabilitación es clave para la recuperación de las capacidades motoras y cognitivas. Por ello, se estudiará cómo personalizar el modelo propuesto para cada paciente, basándonos en un modelo global de asistencia según necesidad.

4. Conclusión

En este trabajo, se ha propuesto una solución basada en Deep Learning para aprender del criterio de un terapeuta cuándo un paciente necesita asistencia durante terapias de rehabilitación asistidas por robots. El modelo propuesto ha sido entrenado y evaluado con datos de diferentes pacientes durante una modalidad de juego punto a punto. Se han aplicado una serie de transformaciones a las trayectorias realizadas por los pacientes antes de introducirlas como entradas del modelo con el fin de universalizar el método.

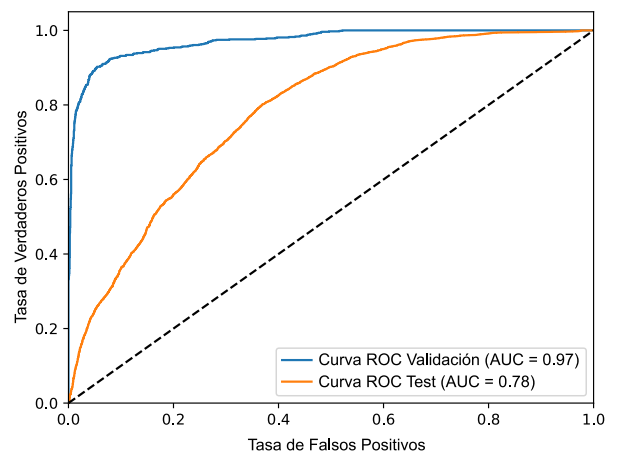


Figura 4: Curvas Receiver Operating Characteristic (ROC) obtenidas con el clasificador propuesto para los conjuntos de datos de validación y prueba.

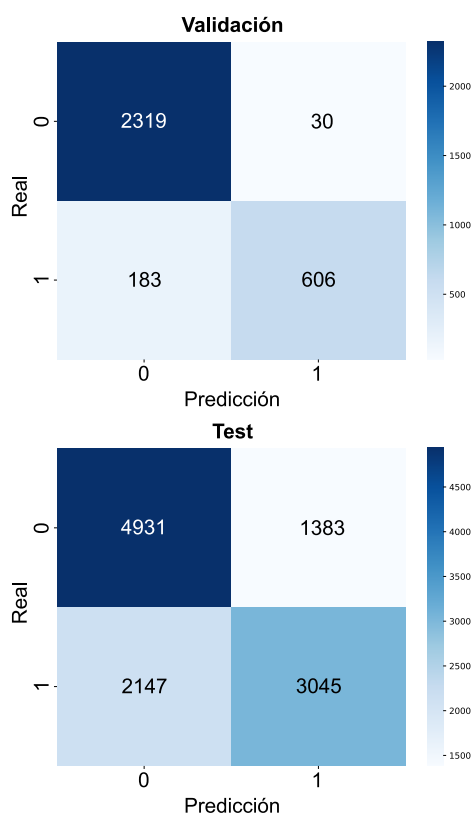


Figura 5: Matrices de confusión obtenidas con el clasificador propuesto para los conjuntos de datos de validación y test.

El modelo propuesto ha sido evaluado utilizando diferentes métricas, y se ha logrado una precisión del 93,21 % y un F1-Score del 85,05 % con el conjunto de datos de validación, mientras que se obtiene una precisión del 69,32 % y un F1-Score del 63,31 % con usuarios que no participan en el proceso de aprendizaje del modelo.

Consideramos que los resultados obtenidos son prometedores, y se pretende ampliar el número de pacientes para mejorar el método propuesto de asistencia según necesidad para terapias asistidas por robots. Además, se estudiará cómo personalizar el modelo para cada paciente partiendo de un modelo global, utilizando técnicas como el aprendizaje por transferencia.

Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Universidades mediante la beca de Formación de Profesorado Universitario FPU20/05137, mediante el proyecto PID2019-108310RB-I00, y mediante el proyecto PID2022-139957OB-I00; y por la Agencia Estatal de Innovación mediante el proyecto PLEC2022-009424 y el proyecto TED2021-130431B-I00.

Referencias

Ahmed, S., Mayo, N. E., Higgins, J., Salbach, N. M., Finch, L., Wood-Dauphinee, S. L., 07 2003. The stroke rehabilitation assessment of move-

ment (stream): A comparison with other measures used to evaluate effects of stroke and rehabilitation. *Physical Therapy* 83 (7), 617–630.

DOI: 10.1093/ptj/83.7.617

Alessandro, L., Olmos, L. E., Bonamico, L., Muzio, D. M., Ahumada, M. H., Russo, M. J., Allegri, R. F., Gianella, M. G., Campora, H., Delorme, R., et al., 2020. Multidisciplinary rehabilitation for adult patients with stroke. *Medicina* 80 (1), 54–68.

Blank, A. A., French, J. A., Pehlivan, A. U., O'Malley, M. K., 2014. Current trends in robot-assisted upper-limb stroke rehabilitation: promoting patient engagement in therapy. *Current physical medicine and rehabilitation reports* 2 (3), 184–195.

DOI: 10.1007/s40141-014-0056-z

Catalán, J. M., Blanco-Ivorra, A., García-Pérez, J. V., Vales, Y., Martínez-Pascual, D., Ezquerro, S., Garrote, A., Costa, T., Lledó, L. D., García-Aracil, N., 2023. Patients' physiological reactions to competitive rehabilitation therapies assisted by robotic devices. *Journal of NeuroEngineering and Rehabilitation* 20 (41).

Catalán, J. M., García-Pérez, J. V., Blanco, A., Ezquerro, S., Garrote, A., Costa, T., Bertomeu-Motos, A., Díaz, I., García-Aracil, N., 2021. Tele-rehabilitation versus local rehabilitation therapies assisted by robotic devices: a pilot study with patients. *Applied Sciences* 11 (14), 6259.

Flach, P. A., 2016. Roc analysis. In: *Encyclopedia of machine learning and data mining*. Springer, pp. 1–8.

Fong, J., Ocampo, R., Gross, D. P., Tavakoli, M., 2020. Intelligent robotics incorporating machine learning algorithms for improving functional capacity evaluation and occupational rehabilitation. *Journal of occupational rehabilitation* 30, 362–370.

Friedrich, M., Gittler, G., Halberstadt, Y., Cermak, T., Heiller, I., 1998. Combined exercise and motivation program: effect on the compliance and level of disability of patients with chronic low back pain: a randomized controlled trial. *Archives of physical medicine and rehabilitation* 79 (5), 475–487.

DOI: 10.1016/S0003-9993(98)90059-4

Gulli, A., Pal, S., 2017. *Deep learning with Keras*. Packt Publishing Ltd.

He, K., Zhang, X., Ren, S., Sun, J., 2015. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: *Proceedings of the IEEE international conference on computer vision*. pp. 1026–1034.

iDRhA, 2024. <https://idrha.es/>.

URL: <https://idrha.es/>

Koyejo, O. O., Natarajan, N., Ravikumar, P. K., Dhillon, I. S., 2014. Consistent binary classification with generalized performance metrics. *Advances in neural information processing systems* 27.

Macleay, N., Pound, P., Wolfe, C., Rudd, A., 2000. A critical review of the concept of patient motivation in the literature on physical rehabilitation. *Social Science & Medicine* 50 (4), 495–506.

DOI: 10.1016/S0277-9536(99)00334-2

Nichols-Larsen, D. S., Clark, P., Zeringue, A., Greenspan, A., Blanton, S., 2005. Factors influencing stroke survivors' quality of life during subacute recovery. *Stroke* 36 (7), 1480–1484.

Niu, Z., Zhong, G., Yu, H., 2021. A review on the attention mechanism of deep learning. *Neurocomputing* 452, 48–62.

Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., Rahadjeng, I. R., 2020. Sigmoid activation function in selecting the best model of artificial neural networks. In: *Journal of Physics: Conference Series*. Vol. 1471. IOP Publishing, p. 012010.

Ruby, U., Yendapalli, V., 2020. Binary cross entropy with deep learning technique for image classification. *Int. J. Adv. Trends Comput. Sci. Eng* 9 (10).

Serra, J., Pascual, S., Karatzoglou, A., 2018. Towards a universal neural network encoder for time series. In: *CCIA*. pp. 120–129.

Stevens, E., Emmett, E., Wang, Y., C., M., C. W., 2017. The Burden of Stroke in Europe: The challenge for policy makers. *Stroke Alliance for Europe*.

Ulyanov, D., Vedaldi, A., Lempitsky, V., 2016. Instance normalization: The missing ingredient for fast stylization. *arXiv preprint arXiv:1607.08022*.

van Peppen, R., Kwakkel, G., H. van der Wel, B., Kollen, B., Hobbelen, J., Buurke, J., Halfens, J., Wagenborg, L., Vogel, M., Berns, M., van Klaveren, R., Hendriks, H., Dekker, J., 2004. Kngf clinical practice guideline for physical therapy in patients with stroke. review of the evidence. *Netherlands Tijdschrift voor Fysiotherapie* 114 (5).