

Tipo de artículo: artículo de investigación

Uso de la inteligencia artificial en la clasificación médica de pacientes hemipléjicos

Natalia P. Vázquez-Lebrón
<https://orcid.org/0009-0002-5091-4655>
vazquez_131431@students.pupr.edu
Biomedical Engineering Department
Politechnic University of Puerto Rico
Puerto Rico, Estados Unidos

Juan Valera-Marquez
<https://orcid.org/0009-0009-6470-6049>
jvalera@pupr.edu
Biomedical Engineering Department
Politechnic University of Puerto Rico
Puerto Rico, Estados Unidos

Ricardo Bravo-Pérez
<https://orcid.org/0000-0002-8554-3797>
rbravo@pupr.edu
Biomedical Engineering Department
Politechnic University of Puerto Rico
Puerto Rico-Estados Unidos

Correspondence author: vazquez_131431@students.pupr.edu

Received (15/12/2023), Accepted (6/07/2024)

Resumen: Este estudio explora un sistema de redes neuronales basado en aprendizaje automático que utiliza MATLAB para clasificar la hemiplejía, una enfermedad que causa parálisis en un lado del cuerpo. Se desarrolló un algoritmo para categorizar a los pacientes en cuatro tipos de hemiplejía establecidos. Se utilizaron técnicas como el Análisis de Componentes Principales (PCA) y los Mapas Autoorganizados (SOM) para la reducción de la dimensionalidad y la agrupación de datos, mientras que una Red Neuronal Convolutiva (CNN) refinó la clasificación. El algoritmo identificó distintos subgrupos dentro de las categorías, lo que indica una estructura de datos más compleja. A pesar de los resultados prometedores para ayudar al diagnóstico clínico, es necesaria la exploración de estas subcategorías con mayor profundidad.

Palabras clave: inteligencia artificial, hemiplejía, estudios clínicos, SOM, tratamiento médico.

Use of artificial intelligence in medical classification for hemiplegic patients

Abstract. - This study explores a machine learning-based neural network system that uses MATLAB to classify hemiplegia, a disease that causes paralysis on one side of the body. An algorithm was developed to categorize patients into four established types of hemiplegia. Techniques such as Principal Component Analysis (PCA) and Self-Organizing Maps (SOMs) were used for dimensionality reduction and data clustering, while a Convolutional Neural Network (CNN) refined the classification. The algorithm identified distinct subgroups within the categories, indicating a more complex data structure. Despite promising results to aid clinical diagnosis, further exploration of these subcategories is needed.

Keywords: artificial intelligence, hemiplegia, clinical studies, SOM, medical treatment.

I. INTRODUCCIÓN

La hemiplejía, se caracteriza por la parálisis de un lado del cuerpo y puede ser temporal o permanente dependiendo de su gravedad. Este trastorno afecta principalmente a personas que han sufrido accidentes cerebrovasculares, lesiones traumáticas en el cerebro o la médula espinal, o lesiones en la infancia temprana. Los pacientes con hemiplejía enfrentan desafíos significativos en su movilidad y calidad de vida, y su tratamiento adecuado depende de un diagnóstico preciso que clasifique correctamente el tipo de hemiplejía que presentan. La clasificación médica de este trastorno se realiza en cuatro categorías principales (Tipo I, II, III y IV), cada una con implicaciones terapéuticas distintas. El diagnóstico erróneo de la hemiplejía es un problema serio que afecta a una cantidad considerable de pacientes. Según estudios recientes, se estima que más del 20% de los casos de hemiplejía son diagnosticados erróneamente y hasta el 66% de los diagnósticos iniciales son incorrectos. Estas cifras reflejan la necesidad urgente de mejorar los métodos de diagnóstico, ya que un error en la identificación del tipo de hemiplejía puede llevar a tratamientos inadecuados o incluso a la falta de intervención oportuna, lo que impacta negativamente en la recuperación del paciente. La inteligencia artificial (IA) se ha convertido en una herramienta prometedora para abordar los desafíos del diagnóstico en diversas disciplinas médicas, incluida la hemiplejía. Al entrenar algoritmos con datos de casos reales y utilizando métodos de aprendizaje supervisado y no supervisado, se puede aumentar la precisión en la clasificación de este trastorno neurológico. Los patrones de movimiento y las imágenes de diagnóstico pueden ser analizados en profundidad por los sistemas de IA, ofreciendo a los especialistas en salud una visión más detallada y precisa de cada caso.

En este estudio, se exploran las capacidades de la IA para mejorar el diagnóstico de hemiplejía mediante la clasificación automatizada en las cuatro categorías principales. Esta investigación se enfoca en la utilización de algoritmos de aprendizaje supervisado, que permiten al sistema identificar correctamente los patrones de hemiplejía al comparar datos previamente etiquetados, y de aprendizaje no supervisado, donde el sistema detecta por sí mismo nuevos patrones sin intervención humana directa. Ambos enfoques han mostrado resultados prometedores en la clasificación de otros trastornos neurológicos, lo que justifica su aplicación en este contexto. Además, la implementación de IA en el diagnóstico de hemiplejía podría tener un impacto significativo en regiones con acceso limitado a especialistas. En áreas rurales o en países en desarrollo, donde la infraestructura médica es insuficiente, la posibilidad de contar con sistemas de diagnóstico basados en IA podría mejorar notablemente los resultados clínicos. Con herramientas automatizadas que ayuden a realizar diagnósticos más precisos, los profesionales de la salud locales podrían brindar un tratamiento más efectivo y oportuno, disminuyendo la necesidad de referir a los pacientes a centros especializados. La mejora de los métodos de diagnóstico de la hemiplejía mediante la inteligencia artificial no solo tiene el potencial de reducir la tasa de diagnósticos erróneos, sino también de transformar la forma en que se trata a los pacientes en todo el mundo. Este estudio busca contribuir a ese avance, ofreciendo nuevas perspectivas para la clasificación precisa de la hemiplejía y resaltando la importancia de la IA en el campo de la medicina moderna.

II. DESARROLLO

Algunas investigaciones proponen el uso de indicadores difusos, que son variables y no presentan límites estrictos, para analizar el comportamiento cinético de las articulaciones del tobillo y la rodilla durante la marcha [1]. Además, mediante la combinación de estas herramientas, se establece una clasificación más precisa y comprensible de los tipos de marcha espástica, lo que puede ser de gran utilidad para mejorar la toma de decisiones clínicas y optimizar los planes de rehabilitación.

El uso de indicadores difusos en este análisis cinético es relevante porque permite manejar la naturaleza variable y no lineal de las características del movimiento en pacientes con hemiplejía espástica. A diferencia de los métodos tradicionales de análisis, esta técnica no se limita a definir categorías rígidas, sino que trabaja con rangos de variabilidad, lo que facilita la identificación de patrones únicos en la marcha de cada paciente. Además, la implementación del diagrama de flujo contribuye a una mejor visualización de los resultados y a una mayor facilidad en la interpretación de los datos, haciendo que los hallazgos sean más accesibles para los profesionales de la salud. Este enfoque innovador subraya la importancia de integrar técnicas avanzadas de análisis cinético en el tratamiento y la rehabilitación de pacientes con hemiplejía, ofreciendo una herramienta potencial para personalizar los enfoques terapéuticos y mejorar los resultados clínicos.

Otros autores, destacan la importancia de la tecnología en la rehabilitación de pacientes con hemiplejía [2]. El uso de dispositivos robóticos en la rehabilitación proporciona una terapia controlada y repetitiva, fundamental para promover la neuroplasticidad y mejorar la funcionalidad del miembro inferior afectado. Estos dispositivos permiten personalizar los ejercicios según las necesidades y capacidades de cada paciente, ofreciendo un entrenamiento intensivo que es difícil de lograr con la rehabilitación tradicional. Además, el uso del entrenamiento robótico no solo mejora la fuerza y el rango de movimiento, sino que también puede ayudar a reducir el tiempo de recuperación al proporcionar un apoyo continuo y preciso en el control del movimiento. Este enfoque tiene el potencial de mejorar significativamente la calidad de vida de los pacientes hemipléjicos, ayudándolos a recuperar una mayor independencia funcional en su vida diaria. Autores como Padilla [3], incorporaron indicadores difusos para capturar la naturaleza imprecisa y variable del movimiento en las articulaciones clave durante la marcha, permitiendo una mayor flexibilidad en la clasificación de los patrones de marcha. Este método difuso es particularmente útil en la evaluación de la hemiplejía, donde las características del movimiento no siempre siguen un patrón rígido, sino que varían en función del grado de espasticidad y control motor residual de cada paciente. El análisis de los datos cinemáticos de estas tres articulaciones críticas permite identificar sutiles diferencias entre los tipos de marcha hemipléjica, lo que facilita una clasificación más precisa y personalizada. Este enfoque no solo contribuye a una mejor comprensión de las dificultades de locomoción en estos pacientes, sino que también abre la puerta a tratamientos y rehabilitaciones más específicas, ajustadas a las particularidades cinemáticas de cada individuo.

La lógica difusa, a diferencia de los sistemas de clasificación tradicionales que dependen de categorías discretas, permite manejar la incertidumbre inherente a los movimientos irregulares y los grados variables de disfunción motora que son característicos en la marcha de los pacientes hemipléjicos [4]-[6]. Esta flexibilidad en la clasificación es esencial, ya que la marcha hemipléjica no sigue un patrón uniforme y puede fluctuar según la gravedad de la espasticidad, el equilibrio y el control muscular. Al aplicar este sistema, es posible personalizar la evaluación clínica y adaptar los programas de rehabilitación a las necesidades específicas de cada paciente, mejorando la capacidad de los profesionales de la salud para tomar decisiones informadas sobre el tratamiento y seguimiento. Además, el uso de lógica difusa en la clasificación de la marcha subraya su potencial para mejorar el diagnóstico y la intervención temprana en diversas afecciones neurológicas relacionadas con la movilidad.

Otras investigaciones [6], proponen una innovadora aplicación de las máquinas de vectores de soporte (SVM) para clasificar la hemiplejía espástica, lo que marca un avance en el uso de herramientas de aprendizaje automático en la rehabilitación médica. Las SVM son modelos supervisados que encuentran un hiperplano óptimo para separar las diferentes clases de datos, lo que es particularmente útil en la clasificación de patrones complejos como los que se observan en pacientes con hemiplejía espástica. Al aplicar esta técnica, el estudio logra identificar con precisión las diferencias entre los diversos grados de espasticidad y disfunción motora, lo que facilita la creación de subgrupos más detallados dentro del diagnóstico de hemiplejía espástica.

Este enfoque no solo mejora la precisión en la clasificación, sino que también permite un análisis más objetivo y reproducible en comparación con los métodos clínicos tradicionales. El uso de SVM en este contexto subraya su potencial para optimizar los procesos de diagnóstico y tratamiento, ofreciendo un enfoque más eficiente y basado en datos para adaptar las intervenciones terapéuticas según las necesidades específicas de cada paciente.

III. METODOLOGÍA

En este trabajo se realizó un proceso metodológico dividido en tres etapas principales para el desarrollo de un modelo basado en un sistema neuronal, utilizando MATLAB como herramienta de implementación.

Etapas 1: Investigación y Recopilación de Datos

Esta primera fase es fundamental para asegurar que los datos necesarios sean recolectados y preparados adecuadamente antes de entrenar el sistema neuronal. Comprende los siguientes pasos:

1. **Recolección de datos:** Implicó la obtención de datos relevantes para el estudio. Estos datos pueden ser clínicos, imágenes o cualquier otro tipo de información que permitió entrenar el modelo neuronal. En el contexto de la hemiplejía, los datos incluyeron patrones de movimiento y resultados de resonancias magnéticas.
2. **Consideraciones éticas:** Resultó esencial asegurar que el estudio cumpliera con los estándares éticos, especialmente cuando se trata de datos sensibles de pacientes. Esto incluyó garantizar el consentimiento informado, la confidencialidad de la información y el uso adecuado de los datos.
3. **Diseño de la investigación:** Esta etapa implicó definir el marco metodológico del estudio, es decir, cómo se estructuró el experimento, cuáles serán las variables clave y cómo se medirá el éxito del modelo.
4. **Preprocesamiento de datos:** Aquí, los datos crudos se limpiaron y transforman para que pudieran ser utilizados por el modelo neuronal. El preprocesamiento incluyó tareas como la normalización de los datos, el manejo de datos faltantes y la eliminación de ruido.
5. **Selección de características:** Este paso final de la primera fase implicó elegir las variables o características más relevantes que se incluyeron en el modelo. La selección adecuada de características fue crucial para asegurar que el modelo pudiera realizar predicciones precisas.

Etapas 2: Diseño y Entrenamiento del Sistema Neuronal

Una vez que los datos han sido preparados y procesados, se procedió al diseño y entrenamiento del modelo neuronal. Esta fase se dividió en dos partes:

1. **Diseño del sistema neuronal:** En esta etapa se definió la arquitectura del sistema neuronal. Se decidió la cantidad de capas, neuronas en cada capa, el tipo de funciones de activación y otros aspectos técnicos que influyeron en la capacidad del modelo para aprender a partir de los datos.
2. **Entrenamiento del modelo:** Con el diseño del sistema neuronal completado, se procedió al entrenamiento del modelo. El modelo aprendió a identificar patrones en los datos a través de múltiples iteraciones, ajustando los pesos internos para mejorar su capacidad de predicción.

Etapa 3: Pruebas e Interpretación

Una vez entrenado el modelo, se sometió a una serie de pruebas para validar su eficacia y asegurar que los resultados sean interpretables. Esta fase incluyó los siguientes pasos:

1. Validación y pruebas del modelo: El modelo fue evaluado con datos de prueba que no fueron utilizados durante el entrenamiento. Esto permitió medir la precisión del modelo y asegurarse de que no se ha sobre ajustado a los datos de entrenamiento. Se utilizaron métricas como la exactitud, precisión, sensibilidad, y el área bajo la curva ROC para evaluar el rendimiento.
2. Interpretación de resultados: En esta etapa se analizaron los resultados obtenidos para identificar qué tan bien el modelo ha clasificado los datos y si se ajusta a las expectativas del diseño inicial. Además, se evaluaron los resultados en el contexto de su aplicabilidad clínica, en este caso, en la clasificación de hemiplejía.
3. Documentación y reporte: Finalmente, los resultados y el proceso son documentados adecuadamente para su reporte. Esto incluyó la presentación de los hallazgos de manera clara y comprensible, lo que permitió replicar el estudio y validar los resultados por otros investigadores.

Resumen de herramientas utilizadas

El modelo final fue desarrollado y entrenado utilizando el lenguaje y entorno de programación MATLAB. Esta es una herramienta ampliamente utilizada en investigación para el desarrollo de sistemas neuronales y análisis de datos, gracias a sus bibliotecas especializadas y capacidades avanzadas de procesamiento de datos. Este flujo metodológico asegura que se sigan todas las etapas necesarias, desde la preparación de los datos hasta la interpretación final de los resultados, para desarrollar un modelo neuronal robusto y eficaz en la clasificación de hemiplejía u otros trastornos neurológicos.

IV. RESULTADOS

A. El algoritmo

El algoritmo desarrollado se describe en la figura 1, donde se observa que los datos clasificados del SOM, son la entrada a la red neuronal. Esta última es una red convolucional.

Algoritmo de clasificación
1. Recopilar y preprocesar los datos con 612 características.
2. Aplicar Análisis de Componentes Principales (PCA) para reducir las características a 20 componentes principales.
3. Entrenar un Mapa Autoorganizado (SOM) para identificar patrones y clústeres en los datos.
4. Utilizar los grupos obtenidos como entrada para una red neuronal.
5. Entrenar la red neuronal para clasificar los tipos de hemiplejía y los grupos de control.
6. Evaluar el rendimiento utilizando una matriz de confusión y gráficas de precisión.
7. Interpretar los resultados, incluyendo la identificación de subgrupos no reconocidos previamente.
8. Validar el modelo como herramienta diagnóstica para clínicos.

Fig. 1. Algoritmo de clasificación.

Por otro lado, la clasificación estuvo compuesta de un ajuste dimensional, permitiendo un ajuste por grupos y por tipos (figura 2). El SOM permite además una redimensión de los múltiples factores que se presentan en el estudio.




Fig. 2. Esquema de funcionamiento del algoritmo.

El algoritmo desarrollado clasificó eficazmente los diferentes tipos de hemiplejía utilizando técnicas avanzadas de reducción de dimensionalidad y agrupamiento (figura 3). Inicialmente, el conjunto de datos, que contenía 612 características, se redujo a 20 componentes principales mediante Análisis de Componentes Principales (PCA), lo que facilitó un procesamiento más eficiente y destacó patrones clave. Posteriormente, un Mapa Autoorganizado (SOM) identificó distintos grupos o clústeres, mientras que la red neuronal logró una alta precisión en la clasificación, diferenciando exitosamente entre los grupos de control y los subtipos de hemiplejía, incluyendo el descubrimiento de subgrupos previamente no reconocidos. A pesar de las limitaciones de tiempo, el rendimiento del modelo, evidenciado por la matriz de confusión y las gráficas de precisión, demostró su potencial como una herramienta diagnóstica valiosa para los clínicos.




Fig. 3. Resultados del entrenamiento y validación

En la figura 4 se observa la precisión del modelo al predecir varias clases (eje x) en comparación con las clases verdaderas (eje y). Los valores diagonales representan las predicciones correctas, mientras que los valores fuera de la diagonal indican errores de clasificación. Por ejemplo, el modelo predijo correctamente la clase 0 en 34 ocasiones y la clase 1 en 15, lo que sugiere que el modelo tiene un buen rendimiento en estas clases. Sin embargo, hay cierta confusión en las clases 2, 3 y 4, ya que varios casos fueron mal clasificados, como se evidencia en los números que no están en la diagonal, donde la clase 2 fue confundida con la clase 1 y la clase 4.

Este análisis de la matriz de confusión en el contexto de la clasificación de hemiplejía indica que el modelo tiene un buen rendimiento general, pero aún presenta áreas de mejora. Las clases más pequeñas, que representan subtipos específicos o menos comunes de hemiplejía, son las que muestran mayor confusión, lo que se debe a la naturaleza más sutil de los síntomas. Estos resultados sugieren que el uso de técnicas adicionales, como una mayor recolección de datos para las clases menos representadas o la implementación de métodos de balanceo de clases, podría mejorar aún más la precisión del modelo. Además, estos errores podrían resaltar la necesidad de ajustar los parámetros del modelo o de refinar las características empleadas para diferenciar más claramente entre los subgrupos de hemiplejía.



Fig. 4. Matriz de confusión producto del entrenamiento.

La figura 5 muestra los resultados del Mapa Autoorganizado (SOM), específicamente el gráfico de Neuron Hits, que indica cuántas muestras o datos fueron asignados a cada neurona en la red. Cada hexágono representa una neurona en el SOM, y los números dentro de los hexágonos muestran cuántos datos fueron asignados a esa neurona en particular. Se observa que una de las neuronas ha recibido 18 datos, lo que indica que una parte considerable de los datos cae en esta región del mapa. Esta alta concentración de datos en ciertas neuronas indica la presencia de un grupo o clúster bien definido en el conjunto de datos.

En el contexto de la hemiplejía, los Neuron Hits permiten observar cómo los diferentes subtipos de hemiplejía están siendo clasificados. Se puede observar que algunos subgrupos de datos están mejor representados en ciertas regiones del mapa, mientras que otras áreas tienen una menor densidad de asignaciones, esto indica que los subgrupos son más raros o difíciles de clasificar. Esta información es clave para ajustar los parámetros del SOM o mejorar el modelo, garantizando que los subtipos de hemiplejía menos comunes también sean representados adecuadamente en el modelo de clasificación.




Fig. 5. Neuron Hits para los sub grupos.

CONCLUSIONES

Esta investigación demuestra la viabilidad y el potencial del uso de técnicas de aprendizaje automático, específicamente redes neuronales convolucionales, para clasificar los tipos de hemiplejía. El algoritmo desarrollado identificó y categorizó con precisión varios tipos de hemiplejía. El análisis de componentes principales y los mapas autoorganizados gestionaron eficazmente el conjunto de datos de alta dimensionalidad, revelando información valiosa sobre su estructura. El estudio destaca el potencial de la inteligencia artificial para mejorar los diagnósticos médicos al incrementar la precisión y reducir los errores de diagnóstico. Sin embargo, las limitaciones incluyen la exploración incompleta de las nuevas subcategorías identificadas, lo que indica la necesidad de realizar más investigaciones para comprender su relevancia clínica. En general, los hallazgos sugieren que los modelos de aprendizaje automático pueden descubrir patrones que no son fácilmente detectables por la observación humana, sirviendo como una herramienta complementaria para los profesionales de la salud.

El uso de redes neuronales convolucionales (CNN) en el ámbito médico representa un avance significativo, ya que permite a los algoritmos identificar patrones en datos complejos y no lineales que a menudo escapan a la atención clínica tradicional. En el caso de la hemiplejía, donde los síntomas pueden variar ampliamente entre los pacientes, el análisis de grandes conjuntos de datos mediante técnicas como el análisis de componentes principales y los mapas autoorganizados es clave para lograr una clasificación más precisa. Las CNN no solo automatizan este proceso, sino que también pueden ser ajustadas para capturar características sutiles que pueden contribuir a una comprensión más matizada de la enfermedad, lo que, en última instancia, puede mejorar los enfoques de tratamiento y rehabilitación. Sin embargo, la introducción de inteligencia artificial en la clasificación de enfermedades no está exenta de desafíos. Como se menciona, la exploración de las nuevas subcategorías identificadas aún es incompleta, lo que plantea interrogantes sobre la relevancia clínica de dichos subgrupos. La validación de estos nuevos descubrimientos requerirá una mayor colaboración entre expertos en aprendizaje automático y profesionales de la salud para traducir estos hallazgos en prácticas clínicas útiles. A medida que la inteligencia artificial sigue evolucionando, será crucial continuar refinando estos modelos, asegurando que el proceso de clasificación esté respaldado por una sólida evidencia clínica y que se evite el riesgo de sobreajuste a los datos o de interpretaciones erróneas.

REFERENCIAS

- [1] U. R. Padilla-Liendo, "Análisis cinético de indicadores difusos en tobillo y rodilla para clasificar la marcha hemipléjica espástica utilizando diagrama de flujo," **Avances en Biomedicina**, vol. 5, no. 2, pp. 66-75, 2016.
- [2] D. B. Medina Vargas, "El entrenamiento robótico en la funcionalidad del miembro inferior en pacientes hemipléjicos del IESS de la ciudad de Ambato", Bachelor's thesis, Universidad Técnica de Ambato-Facultad de Ciencias de la Salud-Carrera de Terapia Física, 2015.
- [3] U. R. Padilla Liendo, "Clasificación de la marcha hemipléjica utilizando las características difusas de los indicadores cinemáticos en tobillo, rodilla y cadera," **Interciencia**, vol. 41, no. 9, pp. 633-638, 2016.
- [4] A. Yardimci, "Fuzzy logic-based gait classification for hemiplegic patients," in **Advances in Intelligent Data Analysis VII: 7th International Symposium on Intelligent Data Analysis, IDA 2007, Ljubljana, Slovenia, September 6-8, 2007. Proceedings 7**, Berlin Heidelberg: Springer, 2007, pp. 344-354.
- [5] J. Riad, Y. Haglund-Akerlind, and F. Miller, "Classification of spastic hemiplegic cerebral palsy in children," **Journal of Pediatric Orthopaedics**, vol. 27, no. 7, pp. 758-764, 2007.
- [6] A. J. Salazar, O. C. De Castro, and R. J. Bravo, "Novel approach for spastic hemiplegia classification through the use of support vector machines," in **The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, vol. 1, pp. 466-469, Sept. 2004.