

Redes Neuronales Artificiales para Cuantificar la Motricidad en Niños con Hemiparesia Cerebral

L. E. Anaya Campos^{1*}, I. Quiñones Urióstegui¹, Y. Quijano González¹, V. Bueyes Roiz¹

¹ Laboratorio de Análisis de Movimiento, Instituto Nacional de Rehabilitación Luis Guillermo Ibarra Ibarra, CDMX, México
leonardo.anayac@gmail.com

Resumen

En busca de una herramienta confiable para poder cuantificar la motricidad del miembro superior, este trabajo busca mejorar la forma de clasificación de la afectación motriz en miembro superior en pacientes con alteraciones o patologías en el sistema nervioso central, proponiendo una nueva forma objetiva de medir y clasificar el grado de capacidad de movimiento. Utilizando el método de redes neuronales artificiales para cuantificar con mayor eficacia el nivel de motricidad en cinco niveles de la nueva escala de clasificación propuesta SSULF para tener una mejor valoración y grado de la funcionalidad motriz del miembro superior en pacientes diagnosticados con hemiparesia cerebral utilizando los resultados obtenidos con la herramienta de valoración Sorting Block Box, logrando clasificar con eficacia más del 95 % de los pacientes del grupo control y más del 90 % de los pacientes con su mano afectada en algún nivel de la escala SSULF entre los niveles 2 y 4.

Palabras clave: Clasificación de datos, redes neuronales artificiales, suavidad de movimiento.

1 Introducción

La Parálisis Cerebral (PC) es un grupo de trastornos pre, post y perinatales permanentes del desarrollo, movimiento y postura debidos a alteraciones no progresivas ocurridas durante el desarrollo cerebral, producto de lesiones del Sistema Nervioso Central[1]. La UNICEF estima que el 80 % de la población con algún tipo de discapacidad motriz, vive en países en vías de desarrollo[3]; por su lado, en México, la Secretaría de Salud reporta que la novena causa de atención en el Sistema Nacional para el Desarrollo Integral de la Familia es la PC, además de existir una tasa de 3 casos por cada 10,000 infantes con hemiparesia espástica[1][2].

La parálisis cerebral se caracteriza por la dificultad en la transmisión de los mensajes enviados por el cerebro a los músculos. Dentro de este contexto, espasticidad significa rigidez en los músculos; las personas que tienen esta clase de parálisis cerebral encuentran dificultad para controlar uno o grupos de músculos debido a algún grado de espasticidad en las mismas (ver Figura 2), a mayor espasticidad será menor capacidad motriz sobre el miembro.[2].

2 Metodología

2.1 Suavidad del movimiento y su valoración

La suavidad del movimiento es una cualidad relacionada con la continuidad o no intermitencia de un movimiento, independientemente de su amplitud y duración. La intermitencia en este contexto se refiere a movimientos que alternativamente desaceleran y aceleran, y más intermitencia corresponde




Fig. 1. Podemos diferenciar la parálisis cerebral en función de la parte del cuerpo que se encuentra afectada, teniendo así una clasificación por criterios topográficos. La hemiparesia (centro) se produce cuando la discapacidad se presenta únicamente en la mitad izquierda o derecha del cuerpo.[1]

a movimientos no suaves. La intermitencia de movimiento generalmente se observa como caídas en el perfil de velocidad de un movimiento o períodos finitos distintos de cero de velocidad cero (es decir, detención del movimiento) durante un movimiento en curso. Una caída en un perfil de velocidad es un punto donde la segunda derivada de la posición va a cero, y resalta un período de desaceleración seguido de aceleración, que es una marca de intermitencia de movimiento. Por otro lado, un período de detención de movimiento representa una forma extrema de intermitencia donde todas las derivadas de posición van a cero por una duración finita distinta de cero. Cuanto más largo es el período de arresto, más intermitente es el comportamiento[7].

La suavidad del movimiento se midió con un sensor inercial (IMU) que se coloca en el dorso de la mano a medir[4] y el *Sorting Block Box* (SBB), ver figura 2, que consta de un tablero con huecos de diferentes formas geométricas (cuadro, triángulo, círculo, rectángulo) y 4 piezas de madera que deben ser colocadas en sus respectivos espacios; dicho tablero tiene por dentro diversos sensores que detectan la fuerza del movimiento y si la pieza está o no en su lugar[5][6].

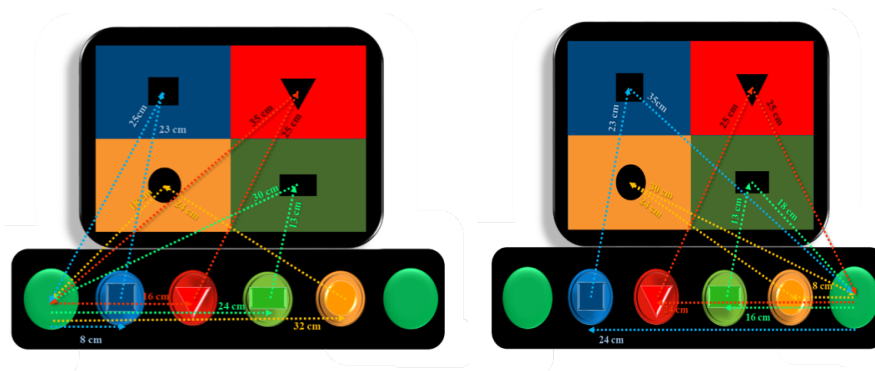


Fig. 2. Tablero Sorting Block Box. Se muestran las distancias (cm) de las trayectorias ideales recorridas por el brazo izquierdo (izq) y el brazo derecho (der).

Cada trayectoria delimita un submovimiento[4], es decir, un submovimiento es el de tomar la pieza naranja con la mano derecha y colocarlo en su orificio y otro submovimiento es la acción de apretar el botón verde indicando el final del movimiento; a eso se le llama tarea de llenado. El siguiente submovimiento sería el de tomar la pieza naranja del orificio y regresarla a su lugar original para luego apretar el botón verde indicando el final del movimiento; a esto se le llama tarea de vaciado. Teniendo en cuenta esto, al ser 4 piezas con 4 movimientos y a su vez cada movimiento con 2 submovimientos,

nos da un total de 16 submovimientos a analizar.

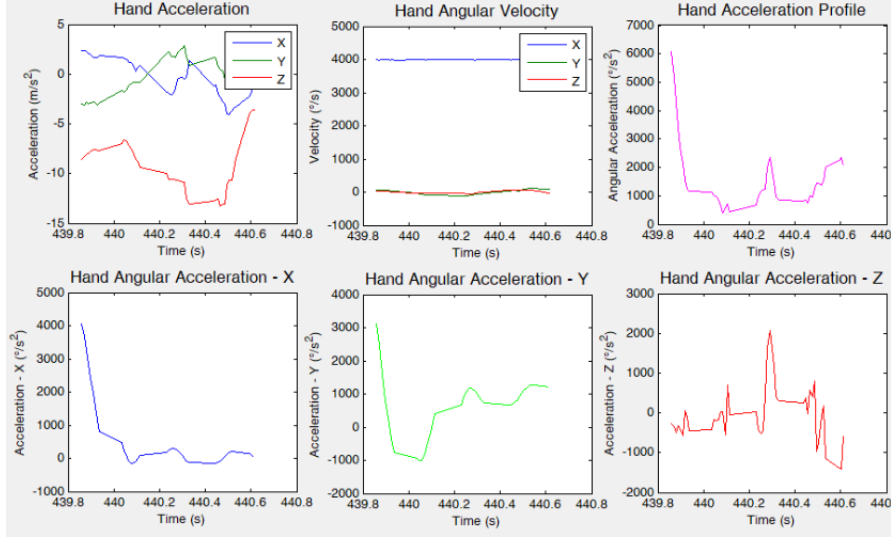


Fig. 3. Se muestra el programa realizado en MATLAB, donde los 6 gráficos son el ejemplo para un submovimiento a analizar. Son la representación gráfica de los submovimientos registrados por el IMU y el SBB, primero la gráfica de la aceleración, luego de la aceleración angular, luego el perfil de la aceleración y finalmente abajo la aceleración angular en cada uno de los ejes X, Y y Z. Gracias a la sincronización del SBB con el IMU, podemos seccionar cada intento en los 16 submovimientos.

Estos submovimientos serán valorados con el uso de tres métricas (SALM, PM y LDJM) que nos proporcionarán los valores numéricos de medición de los niños. Estas métricas se determinaron mediante la lectura de bibliografías y estudios previos realizados como métricas de suavidad de movimientos[4][6][7].

La métrica de longitud de arco espectral (Spectral Arc Length Metric, SALM) se define como el tamaño de la curva del espectro de Fourier del perfil de velocidad de un movimiento:

$$n_{sal} = - \int_0^{\omega_c} \sqrt{\left(\frac{1}{\omega_c}\right)^2 + \left(\frac{dV(\omega)}{d\omega}\right)^2} * d\omega \quad (1)$$

$$V(\omega) = \frac{V(\omega)}{V(0)} \quad (2)$$

Donde en la ecuación, el $\omega_c = 20$ Hz, es la banda de frecuencia que cubre los movimientos humanos normales y anormales y $V(\omega)$ es el espectro de magnitud de Fourier de $v(t)$.

La métrica de picos (Peaks Metric, PM) es la cantidad de máximos locales en el perfil de velocidad de un movimiento:

$$n_{pm} \triangleq -\#\{v_{max}\} \quad (3)$$

$$v_{max} \triangleq \left\{ v(t) : \frac{dv}{dt} = 0 \ \& \ \frac{d^2v}{dt^2} < 0 \right\} \quad (4)$$

2.3 Clasificación de los datos

Después del proceso de experimentación, los datos obtenidos de un total de 2784 valoraciones con el SBB, los resultados obtenidos a partir de de las tres métricas del grupo control y los pacientes diagnosticados se usaron para construir una validación para grupos extremos utilizando el método k-means de agrupamiento[15][16].

El siguiente diagrama de dispersión muestra la distribución de los datos de las 16 subtareas diferentes desde Sorting Block Box con el uso de Shimmer IMU en la comparación de cada una de las tres métricas y utilizando el método de agrupamiento kmeans obtuvimos los resultados que se muestran en la Figura 5, donde cada color diferente representa una clase diferente de la clasificación, con un total de 5 clústeres. Ahora usando estos resultados, obtuvimos para la clasificación SSULF los límites de los parámetros de cada clase SSULF de la métrica SALM:

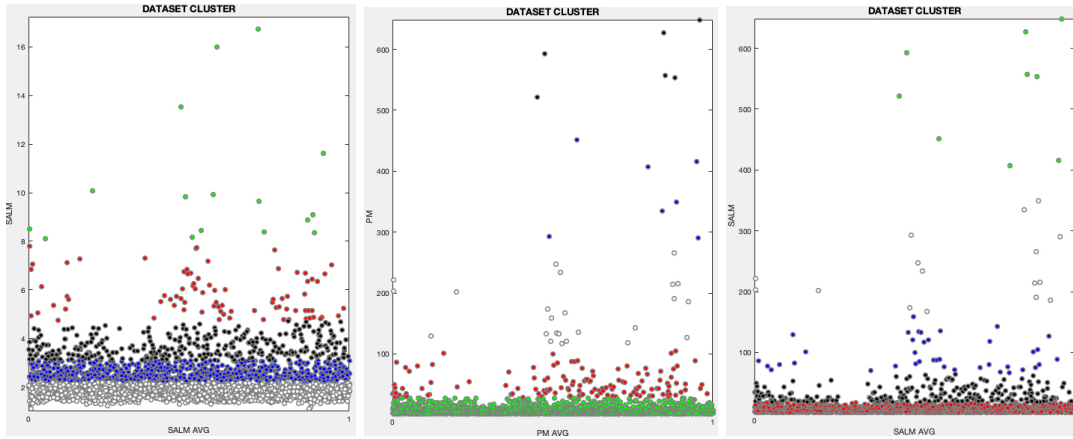


Fig. 5. Nube de datos.

$$SSULF_{SALM} = \begin{cases} 1. & 0 \leq SALM \leq 2,2123 \\ 2. & 2,2123 < SALM \leq 3,2256 \\ 3. & 3,3356 < SALM \leq 5,1387 \\ 4. & 5,1387 < SALM \leq 9,0882 \\ 5. & 9,0882 < SALM \end{cases} \quad (7)$$

$$SSULF_{PM} = \begin{cases} 1. & 0 \leq PM \leq 35,1 \\ 2. & 35,1 < PM \leq 135,85 \\ 3. & 135,85 < PM \leq 292,5 \\ 4. & 292,5 < PM \leq 451,75 \\ 5. & 451,75 < PM \end{cases} \quad (8)$$

$$SSULF_{LDJM} = \begin{cases} 1. & 0 \leq LDJM \leq 27,95 \\ 2. & 27,95 < LDJM \leq 105,3 \\ 3. & 105,3 < LDJM \leq 247,65 \\ 4. & 247,65 < LDJM \leq 451,75 \\ 5. & 451,75 < LDJM \end{cases} \quad (9)$$

2.4 Redes neuronales artificiales

El Perceptrón, desarrollado por Rosenblatt (1958)[11], consiste en una neurona procesadora, con sus elementos de entrada, sumador, activador y de salida. El Perceptrón multicapa (*Multi Layer Perceptron*, MLP) es una Red Neuronal Artificial (*Artificial neural network*, ANN) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón.




Fig. 6. Ejemplo de la estructura de un Perceptrón multicapa (MLP).

El perceptrón es entrenado presentándole un conjunto de patrones de entrenamiento en forma repetida. Cada patrón de entrenamiento es una pareja formada por un vector de entrada x y su vector de salida y deseable. La dimensión del vector de entrada es igual al número de neuronas de la capa de entrada, en tanto que la dimensión del vector de salida es igual al número de neuronas de la capa de salida[11].

Después de haber entrenado la red neuronal con los valores adecuados obtenidos, cuando se les presente un patrón arbitrario de entrada de los pacientes a evaluar, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a las características que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento, lo cual las hace capaces de clasificar a los pacientes según su afectación motriz [9][11][12].

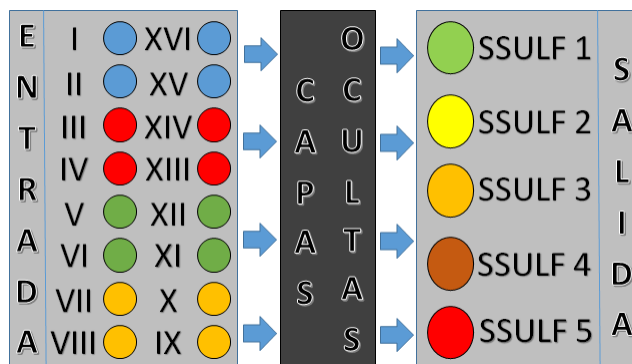


Fig. 7. Diagrama de la red neuronal con 16 entradas (una por cada submovimiento) y de las 5 salidas (una para cada clase de SSULF).

3 Resultados y Discusión

Utilizando estos valores de límite para cada métrica de SSULF de las ecuaciones 7, 8 y 9, se entrenaron redes neuronales de distintos valores en capas ocultas para entrenar a identificar el valor de SSULF de cada nivel. Con la red neuronal entrenada, se ingresa el valor de las 16 subtareas por intento y la red nos regresa la clasificación, en este caso el nivel de valoración en el que cae el sujeto, de la escala SSULF, como se puede ver en la Figura 8.

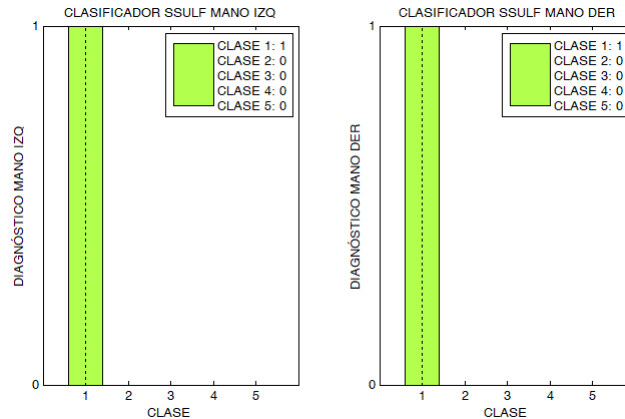


Fig. 8. Muestra el ejemplo de la valoración final de un paciente con la escala SSULF utilizando como base la clasificación mediante las redes neuronales artificiales.

Como resumen del procedimiento y tomando como referencia la Figura 8, cada paciente obtiene un solo resultado de su experimentación. En este caso, podemos ver como el resultado para dicho paciente es que obtiene un SSULF nivel 1 para su mano izquierda y SSULF nivel 1 para su mano derecha, queriendo decir que su calificación cae en valores normales establecidos con el grupo control. El nivel de la clasificación SSULF indica en el nivel 1 normalidad, nivel 2 una afectación leve hasta llegar al nivel 5, siendo este una afectación grave acorde a lo obtenido con las ecuaciones 7, 8 y 9 de cada métrica empleada.

Más de un 95 % de los pacientes del grupo control fueron clasificados con este método en SSULF-1, siendo esté como rango de motricidad normal como sería de esperarse. En el caso de los pacientes del grupo afectado, el 90% de los resultados con su mano afectada cayeron entre los niveles de SSULF-2 al SSULF-4, esto se debe al nivel de afectación de cada uno en particular.

4 Conclusión

El análisis segmentado presentado se enfoca primordialmente en la valoración funcional del miembro superior con la ayuda del SBB. En este estudio, el uso de este dispositivo SBB como método de tomar información acerca del movimiento de sujetos con diagnosticados con parálisis cerebral y su entendimiento ha demostrado nuevamente su eficacia y facilidad de uso.

Las movimientos de las acciones de llenado y vaciado del tablero SBB pudieron ser valoradas a través de tres métricas de suavidad (SALM, PM, LDJM). Estas métricas resultaron ser efectivas en la valoración de funcionalidad entre sujetos sanos y sujetos diagnosticados con hemiparesia. Las tres métricas resultaron ser capaz de demostrar las diferencias entre un miembro superior afectado y no afectado de un mismo individuo, como pudimos ver en la Figura 4.

Antes de la utilización de las redes neuronales se tenían los 16 resultados de las 16 subtareas, lo cual hacía complicado el poder relacionar los resultados entre sí del mismo paciente, con la implementación de este modelo matemático, se pudo reducir de las 16 valoraciones a una sola representada con la métrica SSULF para la mano afectada y para la mano no afectada, facilitando un futuro diagnóstico clínico.

Declaración de conflictos de interés

Los autores declaran no tener ningún conflicto de interés para este trabajo.

Referencias

- [1] Salud Secretaría de, SEMAR, and SEDENA, “Resumen de Evidencias y Recomendaciones, evaluación diagnóstica del niño con parálisis cerebral en el tercer nivel de atención,” 2009.
- [2] M. Seer Yee, “Impact of cerebral palsy on the quality of life in patients and their families,” *Neurology Asia*, vol. 14, 2009.
- [3] I. Lagunju, “The child with cerebral palsy in a developing country: diagnosis and beyond,” *Journal of Pediatric Neurology*, vol. 7, no. 4, 2009.
- [4] Anaya, L., Quijano, Y., Quiñones, I., Alessi, A., Bueyes, V., Chong, E., “Segmentación de Tareas en el Dispositivo Sorting Block Bock, para la Valoración Funcional del Miembro Superior de Niños con Parálisis Cerebral”, *Memorias del XXXIX Congreso Nacional de Ingeniería Biomedica*, 2016.
- [5] J. Klein, A. Chen and E. Burdet, “Instrumented sorting block box for children, a preliminary experiment” 2011 IEEE International Conference on Rehabilitation Robotics, June 29 - July 1, 2011.
- [6] Quijano Y, et al, Upper Limb Functional Assessment of Children with Cerebral Palsy Using a Sorting Box. En prensa 36 Annual International IEEE EMBS Conference 2014
- [7] Sivakumar Balasubramanian, Alejandro Melendez-Calderon, Agnes Roby-Brami, Etienne Burdet. On the analysis of movement smoothness. *Journal of NeuroEngineering and Rehabilitation*, Bio-Med Central, 2015, 12 (1), pp.112.
- [8] Anaya, L., Quijano, Y., Quiñones, I., Alessi, A., Bueyes, V., Chong, E., “Segmentación de Tareas en el Dispositivo Sorting Block Bock, para la Valoración Funcional del Miembro Superior de Niños con Parálisis Cerebral”, *Memorias del XXXIX Congreso Nacional de Ingeniería Biomédica*, 2016.
- [9] DARPA. (1988) *Neural Network Study*. Fairfax, VA: AFCEA Press.
- [10] Dayhoff, J (1990). *Neural Network Architectures: an introduction*. New York: Van Nostrand Reinhold.
- [11] Minsky, M & Pappert, S (1969). *Perceptrons*. Cambridge, MA: MIT Press.
- [12] Yoon, Y et al. (1989). “A desktop neural network for dermatology diagnosis”. *J. Neural Network Computing*. 1: 43- 52.
- [13] S.Y. Kung, “*Digital Neural Networks*”, Prentice Hall, 1993.
- [14] E. Castillo Ron, Á. Cobo Ortega, J. M. Gutiérrez Llorente, R. E. Pruneda González, “Introducción a la Redes Funcionales con Aplicaciones”, Paraninfo, 1999.
- [15] Hartigan, J.A., Wong, M.A., A k-means clustering algorithm, *AppStat*(28), 1979, pp. 100-108. DOI Link BibRef 7900.
- [16] Selim, S.Z., and Ismail, M.A., K-Means-Type Algorithms: A Generalized Convergence Theorem and Characterization of Local Optimality, *PAMI*(6), No. 1, January 1984, pp. 81-87. See also *Fuzzy C-Means: Optimality of solutions and effective termination of the algorithm*.
- [17] Navarro, A., Allen, C.R., Adaptive Classifier Based on K-Means Clustering and Dynamic Programming, *OptEng*(36), No. 1, 1997, pp. 31-38. Journal ref. may not be right.