

# Minería de Datos usando Metaplasticidad Artificial en la Rehabilitación Cognitiva de Pacientes con Daño Cerebral

A. Marcano-Cedeño<sup>1,2</sup>, P. Chausa<sup>1,2</sup>, C. Cáceres<sup>1,2</sup>, A. García<sup>3</sup>, R. López<sup>3</sup>, A. García<sup>3</sup>, T. Roig<sup>3</sup>, J.M. Tormos<sup>3</sup>, Enrique J. Gómez<sup>1,2</sup>

<sup>1</sup> Grupo de Bioingeniería y Telemedicina. ETSIT- Universidad Politécnica de Madrid, España.  
amarcano,pchausa,ccaceres,egomez@gtb.tfo.upm.es

<sup>2</sup> Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN), Madrid, España .

<sup>3</sup> Departamento de Investigación, Institut Guttmann, Badalona, España. agaciar, rlopez,agarciam,troig,jmtormos@guttmann.com

## Resumen

*El propósito principal de esta investigación es la aplicación de la Metaplasticidad Artificial en un Perceptrón Multicapa (AMMLP) como una herramienta de minería de datos para la predicción y extracción explícita de conocimiento del proceso de rehabilitación cognitiva en pacientes con daño cerebral adquirido. Los resultados obtenidos por el AMMLP junto con el posterior análisis de la base de datos ayudarían a los terapeutas a conocer las características de los pacientes que mejoran y los programas de rehabilitación que han seguido. Esto incrementaría el conocimiento del proceso de rehabilitación y facilitaría la elaboración de hipótesis terapéuticas permitiendo la optimización y personalización de las terapias. La evaluación del AMMLP se ha realizado con datos proporcionados por el Institut Guttmann. Los resultados del AMMLP fueron comparados con los obtenidos con una red neuronal de retropropagación y con árboles de decisión. La exactitud en la predicción obtenida por el AMMLP en la subfunción cognitiva memoria verbal-visual fue de 90.71 %, resultado muy superior a los obtenidos por los demás algoritmos.*

## 1. Introducción

El daño cerebral adquirido (DCA) es una lesión del cerebro causada por un evento después del nacimiento y afecta a las funciones cognitivas, físicas, emocionales, etc., de la persona que lo sufre. En la actualidad es uno de los problemas de salud pública más importantes siendo la causa principal de discapacidad a nivel mundial.

Las personas con DCA pasan por un proceso de rehabilitación que suele centrarse en áreas específicas (rehabilitación de funciones cognitivas, motoras, sensoriales, etc.). La rehabilitación de las funciones cognitivas tiene el objetivo de aumentar la autonomía y la calidad de vida de los pacientes (minimizar y/o compensar alteraciones funcionales) y de sus familiares [1]. El rápido crecimiento del número de casos de DCA y la importancia de las funciones cognitivas en las actividades de vida diaria demandan programas de rehabilitación cognitiva más eficientes.

La reciente introducción de sistemas automatizados para la rehabilitación cognitiva genera grandes cantidades de datos [2] que, correctamente analizados, nos permitirían obtener nuevo conocimiento para evaluar y mejorar la eficacia del proceso de rehabilitación. Diferentes métodos estadísticos y de minería de datos se han aplicado para

predecir los resultados clínicos de la rehabilitación de pacientes con DCA. Los métodos más utilizados son los árboles de decisión (DT) y las redes neuronales artificiales (ANN) [3]. Encontramos en la literatura diversos estudios que tienen como objetivo comparar estas técnicas con otros métodos predictivos como los modelos de regresión múltiple y logística, AdaBoost o máquina de vectores soporte (SVM) [3, 4, 5]. Siguiendo esta línea y centrándonos específicamente en el área de la rehabilitación cognitiva, este artículo presenta los resultados obtenidos al analizar datos capturados por la plataforma de Telerrehabilitación Cognitiva PREVIRNEC mediante diferentes técnicas de minería de datos. El objetivo principal de este estudio es la aplicación de la metaplasticidad artificial en un perceptrón multicapa (AMMLP), para la predicción y la extracción de conocimiento del proceso de rehabilitación cognitiva. Para evaluar la precisión del algoritmo, los resultados se compararon con una red neuronal de retropropagación (BPNN) y con árboles de decisión.

## 2. Metaplasticidad Artificial: AMMLP

El concepto biológico de la metaplasticidad fue definido por W.C. Abraham y actualmente es ampliamente usado en áreas tales como la biología, neurociencia, psicología y neurología entre otras [6]. La metaplasticidad se define como la inducción de cambios sinápticos dependientes de la actividad sináptica previa [6]. Recientemente investigadores como Marcano-Cedeño [7], y Andina [8] han introducido y modelado la propiedad biológica de la metaplasticidad en el campo de las redes neuronales obteniendo excelentes resultados.

El perceptrón multicapa (MLP) ha sido utilizado con éxito en muchos problemas de clasificación y reconocimiento de patrones y en particular para el DCA [4]. La funcionalidad de la topología del MLP está determinada por un algoritmo de aprendizaje. El algoritmo de retropropagación es el más usado para entrenar a los MLP pero sufre de algunas limitaciones y problemas de lentitud, convergencia y exactitud durante el entrenamiento. Proponemos un algoritmo de entrenamiento basado en la metaplasticidad biológica. La metaplasticidad artificial se modela como la capacidad de cambiar la eficiencia de la plasticidad dando más relevancia a los patrones con menos frecuencia y restando

relevancia a los patrones frecuentes [7,8]. Modelamos el entrenamiento del MLP con la siguiente función de peso

$$f(x) = \frac{A}{\sqrt{2\pi}e^{-\frac{x^2}{2B}}}$$

donde A y B son parámetros que se estiman empíricamente. Nótese que se ha supuesto que las probabilidades *a posteriori* siguen una distribución Gaussiana. Si esto no se corresponde con la realidad, puede no converger.

### 3. Materiales y métodos

#### 3.1. Descripción de los datos

El Institut Guttmann (IG) es un hospital especializado en la rehabilitación integral y el tratamiento médico/quirúrgico de las personas que sufren lesiones de la médula espinal, DCA y otras discapacidades físicas graves de origen neurológico. Una de las áreas de experiencia del IG es la rehabilitación cognitiva de pacientes con DCA.

El primer paso del proceso de rehabilitación cognitiva es aplicar a los pacientes una batería de tests neuropsicológicos (BTN) para evaluar el estado de sus funciones cognitivas. La BTN utilizada por el IG consta de 27 tests que cubren los principales dominios cognitivos (atención, memoria y función ejecutiva). Todos los tests BTN se normalizaron en una escala de 0 a 4 donde 0=normalidad, 1 = afectación leve, 2 = afectación moderada, 3 = afectación grave, 4 = afectación muy grave. Después de la valoración inicial, los pacientes comienzan un programa de rehabilitación mediante el uso de la plataforma PREVIRNEC. El tratamiento tiene una duración de 3 a 5 meses y durante el mismo los pacientes realizan tareas adaptadas a su nivel de afectación. Una vez finalizado el programa de rehabilitación, los pacientes son valorados nuevamente con la misma BTN. La diferencia entre las valoraciones pre-tratamiento y post-tratamiento nos indican la evolución del paciente en las distintas funciones cognitivas. Esta evolución se puede clasificar como: mejora, empeora, normal, NEMS (no evoluciona de manera significativa).

En este estudio se han incluido 123 pacientes con una afectación cognitiva de moderada a muy grave que se sometieron al tratamiento de rehabilitación con la plataforma PREVIRNEC. La edad media de los pacientes es de 36,56 ±6,5 años, con un rango de edad de 18 a 56 años. La muestra está constituida por 91 hombres y 32 mujeres. El estudio se centra en los resultados de una de las 180 tareas que realizaron los pacientes durante su tratamiento con la plataforma PREVIRNEC, enfocada a mejorar la memoria visual-verbal de los pacientes (tarea "Memory").

La base de datos consta de 3396 registros (número de ejecuciones de la tarea "Memory"), de los cuales 1702 (50.12%) corresponden a pacientes clasificados como "MEJORA" y 1694 (49.88%) a pacientes "NO MEJORA" (que englobaría "empeora" y "NEMS"). Para evaluar comparativamente el desempeño de los diferentes métodos presentados en este estudio, todos ellos fueron

entrenados con los mismos datos del conjunto de entrenamiento y prueba. Los métodos fueron entrenados con el 60% de los datos (2021 muestras), de los cuales 1010 pertenecen a la clase mejora y el resto a la clase no mejora. El conjunto de pruebas está compuesto por el 40% restante de los datos (1375 muestras): 692 muestras de mejora y 683 de no mejora. Cada muestra consta de los siguientes atributos:

- Edad: [grupo 1 (17-30 años), grupo 2 (31-56 años), grupo 3 (> 56 años)]
- Nivel educativo: [grupo 1 (estudios primarios), grupo 2 (secundarios) y grupo 3 (universitarios)]
- Resultado de la ejecución de la tarea "Memory": [0-100]
- Resultados de los tests SPAN, RAVL075, RAVL015, RAVL015TR: [0 (normal), 1 (afectación leve), 2 (afectación moderada), 3 (afectación grave), 4 (afectación muy grave)]. SPAN es un test neuropsicológico para medir la inteligencia en adultos y adolescentes. RAVL075, RAVL015, RAVL015TR son tests neuropsicológicos para evaluar el aprendizaje verbal y la memoria.
- Cada muestra se asocia a una etiqueta de clase "MEJORA" o "NO MEJORA", refiriéndose a la evolución del paciente en la subfunción verbal-visual de la función cognitiva de memoria.

#### 3.2. Métodos y software empleado

##### 3.2.1 AMMLP desarrollado en Matlab

Un MLP presenta una función de activación sigmoidea con salida escalar, por lo general en el rango (0,1). Esta propiedad se cumple para todas las neuronas de la red. Se generaron 100 AMMLPs con pesos inicializados aleatoriamente con una distribución normal (media de 0 y varianza de 1). En cada experimento, se entrenaron 100 redes para lograr un resultado medio que fuese independiente de los valores aleatorios iniciales de la ANN. El entrenamiento se detuvo cuando se alcanzó un error de 0.001 y se llevó a cabo con diferentes números de épocas, 1000, 2000 y 3000. La tasa de aprendizaje (LR) fue de 0.2, 0.5 y 1.0, respectivamente. Todos los AMMLP fueron entrenados y evaluados con los mismos conjuntos de datos.

El algoritmo AMMLP fue desarrollado en MATLAB (MATLAB versión 7.6.0.324, R2008a) y en un ordenador Pentium IV de 3.4 GHz con 2 GB de RAM.

##### 3.2.2 BPNN y J48 proporcionados en Weka

Weka es una plataforma de software libre basada en Java que cuenta con gran variedad de algoritmos de minería de datos. En este estudio utilizamos los métodos BPNN y J48, siendo este último una implementación del árbol de decisión C4.5 incluida en Weka.

En el clasificador J48 de Weka, la reducción del factor de confianza disminuye la exactitud en los resultados de la predicción. Para esta investigación se utilizaron tres factores de confianza diferentes (0.25, 0.3 y 0.5) y se obtuvieron tres árboles de decisión diferentes: DT1, DT2

y DT3. Para el BPNN, se utilizó la misma estructura de la red que se aplicó al AMMLP.

## 4. Resultados

La evaluación del rendimiento de predicción de los modelos utilizados en la rehabilitación cognitiva del paciente con DCA se ha dividido en dos partes. En primer lugar se ha determinado la mejor estructura de red y los parámetros óptimos para AMMLP, BPNN y DT. Posteriormente se han aplicado cuatro medidas de rendimiento: el análisis de la especificidad, sensibilidad, y exactitud de la predicción total y la matriz de confusión.

### 4.1.1 Selección de la estructura de red

Para determinar la mejor estructura de red y los parámetros iniciales de la metaplasticidad (ver A y B en la Tabla 1), se utilizaron los parámetros de red recientemente aplicados en otros estudios [7,8]. El algoritmo AMMLP1 presenta la mejor configuración.

Algoritmo	Estructura de red			Parámetros Metaplasticidad		MSE	LR	Épocas
	I	HL	O	A	B			
<b>AMMLP1</b>	<b>4</b>	<b>4</b>	<b>1</b>	<b>37</b>	<b>0.05</b>	<b>0.001</b>	<b>1</b>	<b>2000</b>
AMMLP2	4	5	1	36	0.4	0.001	0.5	1000
AMMLP3	4	5	1	38	0.5	0.001	0.2	3000

**Tabla 1.** Estructuras de red y parámetros de metaplasticidad para el AMMLP

Para poder comparar el rendimiento del AMMLP y el BPNN se utilizó la misma estructura de red en ambos.

Algoritmo	Estructura de red			MSE	LR	Épocas
	I	HL	O			
<b>BPNN1</b>	<b>4</b>	<b>4</b>	<b>1</b>	<b>0.001</b>	<b>1</b>	<b>2000</b>
BPNN 2	4	5	1	0.001	0.5	1000
BPNN 3	4	5	1	0.001	0.2	3000

**Tabla 2.** Estructura de la red para el BPNN.

Para determinar el DT óptimo, se generaron tres DTs diferentes variando el factor de confianza en Weka. El mejor resultado fue el obtenido con DT3 (ver Tabla 3).

Algoritmo	Factor de confianza	Número mínimo de objetos
DTs1	0.5	2
DTs 2	0.3	2
<b>DTs 3</b>	<b>0.20</b>	<b>2</b>

**Tabla 3.** Parámetros para el DT.

### 4.1.2 Medidas de rendimiento

Después de seleccionar la mejor estructura de red y los parámetros óptimos para cada uno de los algoritmos, se aplicó una medida de desempeño para determinar el rendimiento de los algoritmos utilizados. La Tabla 4 muestra la exactitud de la predicción utilizando las diferentes estructuras de AMMLP, BPNN y DT. Tal y como se puede observar en la tabla, los atributos de las

muestras que representan el resultado obtenido en 4 de los tests que forman la batería de evaluación neuropsicológica inicial se han tomado de forma independiente. Esto nos permite analizar el nivel de predicción que nos proporciona cada uno de ellos.

La Tabla 5 muestra la matriz de confusión obtenida por los clasificadores para el atributo SPAN (mejor clasificación obtenida).

Algoritmo	Predicción		
	Mejora	No Mejora	
AMMLP	Mejora	635	57
	No Mejora	52	631
BPNN	Mejora	612	80
	No Mejora	180	503
DT	Mejora	628	64
	No Mejora	69	614

**Tabla 5.** Matriz de confusión obtenida de la mejor clasificación alcanzada por los algoritmos usados en este estudio

La Tabla 6 muestra la especificidad, sensibilidad y exactitud en la precisión obtenida por los clasificadores utilizando el atributo SPAN.

Algoritmo	Predicción		
	Especificidad	Sensibilidad	Exactitud
AMMLPs	92.38%	91.76%	92.07%
BPNNs	88.43%	73.64%	81.09%
DT	90.75%	89.90%	90.33%

**Tabla 6.** Análisis de la predicción obtenida por el AMMLP, BPNN y DT respectivamente.

La Tabla 7 muestra algunos de los datos usados para el análisis del ítem SPAN

Función Memoria: Subfunción Memoria Verbal-Visual				
Edad	Nivel-Edu	Span	Result	Mejora
3	3	4	15	NO
3	3	4	57	SI
3	3	4	75	SI
3	3	4	22	NO
3	3	4	11	NO
3	3	4	68	SI
3	3	4	54	SI
3	3	4	53	NO

**Tabla 7.** Datos del ítem SPAN tomados de la plataforma PREVIRNEC.

## 5. Discusión

Los resultados obtenidos por el AMMLP son claramente superiores a los obtenidos por el BPNN y DT en términos de predicción, especificidad, sensibilidad y precisión. El buen resultado obtenido por el AMMLP permite predecir la probabilidad de que un paciente con DCA mejore a

ALGORITMOS	SPAN	RAVL075	RAVL015	MRAVL015TR	PROMEDIO	PROMEDIO del ALGORITMO
<b>AMMLP1</b>	<b>92.07 %</b>	<b>91.78 %</b>	<b>90.54 %</b>	<b>91.88 %</b>	<b>91.56 %</b>	
AMMLP2	91.18 %	90.50 %	89.78 %	90.15 %	90.40 %	<b>90.71 %</b>
AMMLP3	90.08 %	90.47 %	89.83 %	90.26 %	90.16 %	
<b>BPNN1</b>	<b>81.09 %</b>	<b>80.25 %</b>	<b>79.35 %</b>	<b>80.02 %</b>	<b>80.18 %</b>	
BPNN2	80.40 %	78.50 %	67.60 %	76.30 %	75.70 %	<b>77.98 %</b>
BPNN3	80.86 %	77.75 %	75.26 %	78.40 %	78.07 %	
DT1	88.24 %	88.67 %	86.47 %	88.48 %	87.97 %	
DT2	89.24 %	89.75 %	89.32 %	88.60 %	89.23 %	<b>89.04 %</b>
<b>DT3</b>	<b>90.33 %</b>	<b>90.80 %</b>	<b>89.47 %</b>	<b>89.05 %</b>	<b>89.91 %</b>	

**Tabla 4.** Exactitud en la predicción obtenida por los clasificadores usando diferentes estructuras de red

partir de su perfil de afectación inicial y del resultado obtenido en la ejecución de una tarea concreta de Rehabilitación (tarea “Memory” de la plataforma PREVIRNEC). El análisis de los resultados de predicción junto con la base de datos nos permite además conocer las características de los pacientes y su evolución. Por ejemplo, si analizamos los resultados del ítem SPAN, se puede decir que un paciente que cumple con la siguiente combinación de resultados: SPAN - 4; Nivel educativo - 3; Grupo edad - 3; Resultado  $\geq 54$ , tiene una probabilidad de mejorar de 92.07%. El mismo análisis se puede hacer para cada uno de los ítems usados en esta investigación.

A partir de este estudio se podría analizar la posible relación entre el resultado de ejecución de cada tarea y la mejora del paciente con el fin de obtener el rango terapéutico de forma automática (nivel mínimo de éxito que debe tener el paciente en la ejecución de una tarea para considerar que la rehabilitación está funcionando o que ha obtenido la respuesta clínica deseada). Actualmente, el rango terapéutico se define de manera empírica.

En este estudio se ha considerado cada ejecución de la tarea “Memory” de forma independiente sin tener en cuenta factores temporales. Tampoco se ha incluido la posible influencia de la realización de otras tareas de rehabilitación en la subfunción cognitiva analizada.

## 6. Conclusiones

Esta investigación propone un modelo para predecir la mejora de las funciones cognitivas de pacientes con DCA que siguen un proceso de rehabilitación mediante la plataforma PREVIRNEC. La contribución más importante es la aplicación del AMMLP como una herramienta de minería de datos para la extracción de conocimiento explícito del proceso de rehabilitación cognitiva. La base de datos del Institut Guttmann se utilizó para probar el AMMLP. La exactitud de la predicción obtenida por el AMMLP en la subfunción verbal-visual de la función cognitiva memoria fue de 90.71%, muy superior a la obtenida por el resto de métodos con los que fue comparado. El análisis de los resultados obtenidos por el AMMLP junto con la base de datos permite a los terapeutas conocer las características de los pacientes que mejoran y los programas de

rehabilitación que han seguido. Esto aumenta el conocimiento sobre el proceso de rehabilitación y facilita la elaboración de hipótesis sobre el tipo de programa que está relacionado con la mejora de un determinado tipo de paciente.

## Referencias

- [1] Fundació Institut Guttmann. Tecnologías Aplicadas al Proceso Neurorrehabilitador: estrategias para valorar su eficacia, pp. 446. Fundación Institut Guttmann. Badalona (2008).
- [2] Tormos JM, García-Molina A, García-Rudolph A and Roig T. Information and communication technology in learning development and rehabilitation, *International Journal of Integrated Care*, Vol. 9(5), (2009) ISSN 1568-4156
- [3] Rughani AI, Dumont TM, Lu Z, Josh Bongar MS, Horgan MA, Penar PL, Tranmer BI. Use of an artificial neural network to predict head injury outcome, *J Neurosurg*. Vol. 113(3), 2010, pp. 585-590. doi:10.3171/2009.11.JNS09857
- [4] Andrews PJ, Sleeman DH, Statham PF, McQuatt A, Corruble V, Jones PA, Howells TP, Macmillan CS. Predicting Recovery in Patients Suffering from Traumatic Brain Injury by using Admission Variables and Physiological Data: A Comparison between Decision Tree Analysis and Logistic Regression, *J Neurosurg*. Vol. 97, 2002, pp. 326-336. doi:10.3171/jns.2002.97.2.0326
- [5] Ji SY, Smith R, Huynh T, Najarian K. A comparative analysis of multi-level computer-assisted decision making systems for traumatic injuries, *Medical Informatics and Decision Making*. Vol 9(2), 2009. doi:10.1186/1472-6947-9-2.
- [6] Abraham WC. Activity-dependent regulation of synaptic plasticity (metaplasticity) in the hippocampus, In: N. Kato (Ed), *The Hippocampus: Functions and Clinical Relevance*, pp. 15-26. Elsevier Science, Amsterdam (1996)
- [7] Marcano-Cedeño A, Quintanilla-Domínguez J, Andina D. Breast cancer classification applying artificial metaplasticity algorithm. *Neurocomputing*. Vol. 38(8), 2011, pp. 9573-9579. doi:10.1016/j.neucom.2010.07.019
- [8] Andina D, Álvarez-Vellisco A, Jevtíc A, Fombellida J. Artificial metaplasticity can improve artificial neural network learning, *Automation and Soft Computing*, Vol. 15(4), pp. 681-649. USA (2009). ISSN: 1079-8587

