

AYUDAS A LA INVESTIGACIÓN IGNACIO H. DE LARRAMENDI

CONVOCATORIA AÑO 2019
(Salud)

MEMORIA FINAL

Investigador Principal: Joan Ferri Campos

Entidad: NEURORHB. Servicio de Neurorehabilitación de Hospitales Vithas

País: España

Fundación
MAPFRE

Estudio pronóstico de la funcionalidad y coste-beneficio
tras un traumatismo craneoencefálico mediante técnicas
de machine learning e inteligencia artificial

Memoria final

Investigador principal: JOAN FERRI CAMPOS

Fecha: 30 de abril del 2021

1. Título e identificación de los autores

Autor 1: Joan Ferri Campos

Cargo: Investigador principal

Filiación: NEURORHB. Servicio de Neurorrehabilitación de Hospitales Vithas, Fundación Vithas, Valencia, Spain

Autor 2: Enrique Noé Sebastián

Cargo: Investigador

Filiación: NEURORHB. Servicio de Neurorrehabilitación de Hospitales Vithas, Fundación Vithas, Valencia, Spain

Autor 3: Carolina Colomer Font

Cargo: Investigador

Filiación: NEURORHB. Servicio de Neurorrehabilitación de Hospitales Vithas, Fundación Vithas, Valencia, Spain

Autor 4: Roberto Llorens Rodríguez

Cargo: Investigador

Filiación:

(1) NEURORHB. Servicio de Neurorrehabilitación de Hospitales Vithas, Fundación Vithas, Valencia, Spain

(2) Instituto Interuniversitario de Investigación en Bioingeniería y Tecnología Orientada al Ser Humano, Universitat Politècnica de València, Camino de Vera s/n, 46022 Valencia, España.

Autor 5: Valeriana Naranjo Ornedo

Cargo: Investigador

Filiación: Institute of Research and Innovation in Bioengineering, Universitat Politècnica de València, Valencia, Spain

Autor 6: Adrián Colomer Granero

Cargo: Investigador

Filiación: Institute of Research and Innovation in Bioengineering, Universitat Politècnica de València, Valencia, Spain

Autor 7: Julio José Silva Rodríguez

Cargo: Investigador

Filiación: Institute of Transport and Territory, Universitat Politècnica de València, Valencia, Spain

2. Agradecimientos

Los autores desean agradecer al personal y pacientes del Servicio de Neurorrehabilitación de Hospitales Vithas por su tiempo y confianza.

3. Autores

Dr. Joan Ferri Campos (JF). Director. Neuropsicólogo Clínico por la Universitat de València (1997), experto en Neurorrehabilitación, y Doctor Cum Laude por la misma universidad (2016) por su Tesis Doctoral sobre los Estados Alterados de la Conciencia. Es miembro del Comisión de Vigilancia del Convenio de Daño Cerebral de UNESPA. Es Coordinador del Máster en Neurociencias: cuidados médico-quirúrgicos y rehabilitación del paciente neurológico de la Universidad CEU Cardenal Herrera. Es miembro de las Sociedades Españolas de Neurología y Neuropsicología, así como miembro de la sociedades internacionales de Neurorrehabilitación y de Daño Cerebral. Desde 2018 es el Presidente de la Sociedad Española de Neurorrehabilitación. Ha

participado en más de 20 proyectos de investigación y cuenta con más de 200 comunicaciones en revistas y congresos internacionales y nacionales.

Dr. Enrique Noé Sebastián (EN). Director de Investigación. Licenciado en medicina y cirugía por la facultad de medicina de la Universidad de Navarra (1993), especialista en neurología por la Clínica Universitaria de Navarra (1998) y doctor en medicina por la misma universidad (1999). Desde el año 2000 ocupa la dirección de investigación en NEURORHB. Es miembro de la junta directiva de la Sociedad Española de Neurorehabilitación y de la International Brain Injury Association. Con sus más de 100 artículos científicos, recientemente ha sido reconocido por Revista de Neurología como una de los autores más influyentes en el ámbito de la Neurorehabilitación nacional. Ha participado en 15 proyectos de investigación y ha dirigido 6 tesis doctorales y más de 20 trabajos conducentes a la obtención de titulaciones (Proyectos Final de Carrera, Trabajos Fin de Grado, Trabajos Fin de Máster, etc.).

Dra. Carolina Colomer Font (CC). Directora clínica. Licenciada en medicina por la Universidad de Valencia. Completó su residencia como médico especialista en medicina física y rehabilitación en el Hospital La Fe de Valencia y finalizó su doctorado en la Universitat Autònoma de Barcelona en 2017. Desde el 2005 desempeña el cargo de directora médica de NEURORHB, llevando a cabo labores de dirección y coordinación de los servicios médicos que prestan asistencia a pacientes con daño cerebral adquirido. Ha participado en más de 10 proyectos de investigación y cuenta con más de 100 publicaciones en el ámbito de la Neurorehabilitación.

Dr. Roberto Llorens Rodríguez (RL). Coordinador científico. Ingeniero de Telecomunicaciones por la Universidad Politécnica de Valencia desde 2007, obtuvo el máster en Tecnologías, Sistemas y Redes de Comunicación (2011) y el Doctorado con Mención Internacional Cum Laude en esta misma universidad (2014). Líder del grupo Neurorehabilitation and Brain Research Group de la UPV. Ha participado en más de 30 proyectos de investigación y ha dirigido 2 tesis doctorales y más de 20 Proyectos final de carrera y Trabajos fin de máster.

Valeriana Naranjo Ornedo (VN). Doctora Ingeniera de Telecomunicación (2002) y Catedrática de Universidad de la Universidad Politécnica de Valencia. Durante 2011 y 2012 fue miembro de la comisión de evaluación de proyectos del Ministerio de Economía y Competitividad en el área TIN-TSI, y desde 2013 es Miembro de la Comisión de acreditación ANECA. Ha participado en más de 40 proyectos y contratos, es profesora en la Escuela Técnica Superior de Ingenieros de Telecomunicación desde 1995, y ha dirigido 9 tesis doctorales y más de 100 trabajos conducentes a la obtención de titulaciones (Proyectos final de carrera, Trabajos fin de máster, DEAs, Trabajos fin de grado).

Adrián Colomer Granero (AC). Doctor en Telecomunicaciones por la Universidad Politécnica de Valencia en 2018. Obtuvo su título de ingeniero superior en telecomunicaciones el año 2013 y el máster en tecnologías, sistemas y redes de telecomunicaciones en 2014. Ha participado en más de 10 proyectos y ha dirigido más de 20 Proyectos final de carrera y Trabajos fin de máster.

4. Índice general paginado

1. Título e identificación de los autores	2
2. Agradecimientos	2
3. Autores.....	2
4. Índice general paginado	3
5. Resumen (Objeto y alcance).....	4
6. Abstract en inglés.....	4
7. Introducción y Antecedentes	4
8. Objetivos	6
9. Materiales y Metodología	6
10. Resultados.....	8
11. Discusión	11
12. Conclusiones	13
13. Bibliografía	14
14. Anexos.....	17

5. Resumen (Objeto y alcance)

El objetivo del presente proyecto es mejorar la predicción del grado de funcionalidad de los sujetos que han sufrido un traumatismo craneoencefálico (TCE) y los costes asociados a su tratamiento, mediante técnicas de *machine learning* aplicadas a variables tanto estáticas como dinámicas determinadas con escalas clínicas específicas de un conjunto de sujetos representativo.

6. Abstract en inglés

In neurorehabilitation, prognostic estimation after traumatic brain injury (TBI) is a key element to guide clinical decision making. The aim of this project is to improve the prediction of the degree of functionality of subjects who have suffered a TBI using machine learning techniques applied to both static and dynamic variables determined with specific clinical scales of a representative set of subjects. **Methods:** 516 patients with TBI who were included in a neurorehabilitation program and followed up for a minimum period of 6 months. Of these, 353 had a follow-up assessment one year after admission. To develop the predictor model, four levels or sets of variables have been defined to analyze their predictive capacity on the target variable: 1) sociodemographic variables; 2) variables related to the severity of the injury; 3) functional status at admission; and 4) evolution of the functional status defined by the variation of the FIM score between the initial assessment and the follow-up after 6 months of inclusion in a neurorehabilitation program. The target variable was the total FIM score and its stages. **Results:** Four models were developed based on the predictor variables. The first one that included sociodemographic variables obtained a correlation of 0.50; the model developed from the severity of the injury obtained a correlation of 0.75 and the one that considered the functional situation at admission obtained a correlation of 0.79. Finally, the model with the greatest predictive capacity was the one that included the evolution of functional status after 6 months of neurorehabilitation treatment, showing a correlation of 0.92. **Conclusion:** These results show that the greatest functional predictor value is determined by its response to clinical intervention in a neurorehabilitation program, beyond the sociodemographic variables (age, sex, etc.), the severity of the lesion and the functional situation at the time of admission.

7. Introducción y Antecedentes

Bajo el término daño cerebral adquirido (DCA) se engloban todas aquellas lesiones de cualquier origen que se producen de forma aguda en las estructuras cerebrales de personas que han nacido sin ningún daño, y que causan un deterioro neurológico permanente respecto a la situación previa. Los traumatismos craneoencefálicos (TCE) son la principal causa de DCA en los países desarrollados y presentan una elevada morbi/mortalidad, suponiendo la primera causa de muerte y/o invalidez en menores de 45 años. Los TCE provocan déficits heterogéneos de severidad variable que incluyen alteraciones del nivel conciencia, déficits físicos, neuropsicológicos y/o del funcionamiento psicosocial generando un elevado nivel de discapacidad a largo plazo (Teasell et al., 2007). Su elevada incidencia y repercusión socio-económica ha generado en la literatura científica un creciente interés por esta patología, su rehabilitación y su posible evolución. Prueba de ello es que el conocimiento que poseemos sobre la evolución y sobre los factores que influyen en la supervivencia y discapacidad generada tras un TCE ha aumentado a lo largo de estos últimos años. La creación de unidades o servicios especializados en la valoración, tratamiento y rehabilitación de pacientes que han sufrido un TCE nos ha permitido elaborar modelos predictivos validados, fundamentados científicamente y cada vez más precisos.

Los equipos de neurorrehabilitación requieren de modelos predictivos de recuperación que permitan ajustar expectativas, fijar objetivos realistas e individualizar recursos y esfuerzos para que sus actuaciones sean coste/eficaces. Este aspecto es especialmente relevante en los TCE debido tanto a su alta prevalencia como a la heterogeneidad y severidad de déficits que generan una elevada necesidad de cuidados y asistencia en personas que suelen encontrarse en un momento vital de gran productividad y participación. La capacidad para predecir la recuperación y las posibilidades de reinserción al espacio familiar y sociolaboral que ocupaban estas personas antes de la lesión, es una demanda y una preocupación de pacientes y familiares y un reto para los profesionales del ámbito de la neurorrehabilitación. La construcción de un modelo predictivo es un proceso en el que diferenciamos tres elementos: la selección de las variables que deseamos incluir en el

mismo, la elección del tipo de modelo que deseamos elaborar y finalmente la definición del resultado que deseamos predecir.

En primer lugar, respecto a las variables predictoras en la actualidad sabemos que la morbi-mortalidad que acontece después de un TCE no está determinada por una única variable sino por la interrelación de una pluralidad de factores. Muchos de estos factores son estáticos y por tanto inalterables desde el preciso instante en el que se produce el TCE, entre ellos destacan los factores premórbidos como la edad (peor cuanto más extrema) (Hukkelhoven et al., 2003; Susman et al., 2002), el grado de escolarización (peor cuanto más bajo) (Sherer et al., 1999), el nivel socio-económico del sujeto y/o la presencia-ausencia de apoyo socio-familiar (Hoofien et al., 2002; Leach et al., 1994), el consumo de alcohol-drogas (Sherer et al., 1999), la presencia de otras comorbilidades (Siegel et al., 1991), o los recientes factores genéticos (peor ante la presencia de algún alelo Apo-ε4), entre otros (G et al., 1999). Alguno de los factores pronósticos relacionados con el TCE, que también son estáticos, como el tipo de traumatismo, su etiología (peor cuanto más fenómeno de aceleración-desaceleración se produzca) (Bushnik et al., 2003) o su gravedad (Bates, 2001). Por el contrario, existen factores dinámicos, y por tanto susceptibles de variación interindividual a lo largo de la evolución post-TCE. Entre estos factores dinámicos, destaca la duración de la fase de amnesia postraumática (APT) (Wilson et al., 2000), la duración del periodo de coma (Bushnik et al., 2003), la situación clínica, neurológica (Bushnik et al., 2003), neuropsicológica (Girard et al., 1996) y funcional (Hall et al., 2001) del paciente o las pruebas de neuroimagen (Marshall et al., 1983) u otras exploraciones complementarias que pueden realizarse durante el periodo de recuperación del paciente (Claassen & Hansen, 2001).

En segundo lugar, respecto al modelo o tipo de análisis existen diversas alternativas en función del procedimiento empleado y el resultado esperado. Los análisis univariados estiman la relación entre una única variable predictora y un resultado, no teniendo en consideración la posible influencia de otros factores/variables que podrían contribuir a la asociación observada. Por su parte los análisis multivariados determinan el valor pronóstico de un predictor ajustando a los efectos de otros posibles predictores. Finalmente, los modelos pronósticos combinan la información de diferentes variables pronósticas en un modelo que predice el resultado en pacientes individuales. Los modelos de predicción aportan una estimación de probabilidad pronóstica y se han convertido en una herramienta de marcada relevancia clínica. El modelo pronóstico es por definición un modelo multivariado en el que se consideran los factores de forma conjunta. No obstante, pese a los avances de las últimas décadas, estos modelos proporcionan cálculos probabilísticos con un cierto grado de incertidumbre, expresada como un intervalo de confianza que rodea a la estimación pronóstica. Los enfoques más habituales para el desarrollo de modelos de predicción incluyen análisis de regresión, particiones recursivas, clasificaciones y árboles de decisión (CART) así como redes neuronales. Entre las diferentes metodologías, las redes neurales aportan una especial validez cuando los datos implican una estructura no lineal. La red neuronal es capaz de determinar la probabilidad de cada relación entre diferentes factores y traducir esto en una herramienta de predicción de resultados que es capaz de admitir todos los tipos de datos y es tolerante con los datos ausentes. Desafortunadamente, el proceso de entrenamiento del modelo requiere una gran cantidad de datos; esto limita su precisión en entornos de población relativamente pequeños, que suelen emplear otras herramientas estadísticas menos exigentes.

Por último, respecto a la definición del resultado, la mayoría de los trabajos centrados en la evolución de esta población y en la detección de indicadores pronósticos han dicotomizado los resultados en favorables y desfavorables (Wang et al., 2011). Los estudios de evolución desfavorables se han centrado habitualmente en mortalidad, mientras que las variables de pronóstico favorable habitualmente se han centrado en la recuperación de la conciencia (Giacino et al., 2020). Muy pocos estudios han focalizado su análisis en la situación funcional global de estos pacientes o, si lo han hecho, no suelen centrarse en aspectos concretos relacionados con la funcionalidad (nivel comunicativo, dependencia en actividades básicas o instrumentales de la vida diaria, etc.) sino más bien escalas de funcionalidad global como la *Glasgow Outcome Scale Extended* o la *Disability Rating Scale*, entre otras.

En resumen, los modelos predictivos existentes se han centrado en datos demográficos y en comorbilidades previas de los pacientes, y en variables relacionadas con la lesión en los instantes o días posteriores al accidente. De todas las variables estudiadas hasta la fecha, se ha reportado que la edad, la etiología y el periodo de tiempo sin respuesta poseen la mayor capacidad predictora de recuperación. Sin embargo, los modelos existentes comparten algunas limitaciones comunes como son la dicotomización de los resultados y

la falta de inclusión de variables dinámicas. Por una parte, la mayor parte de los trabajos publicados dicotomizan los resultados en favorables o desfavorables en base a escalas de funcionalidad global. Pese a que existe un consenso general sobre el uso de estas escalas, son escalas muy globales que no consiguen reflejar el nivel de funcionalidad e independencia de los pacientes ni la necesidad de asistencia y cuidados. Por otra, los estudios previos no contemplan la progresión clínica de los pacientes como otra posible variable predictiva. Debido a limitaciones temporales y económicas de la prestación de servicios sanitarios en países de nuestro entorno, y especialmente en Estados Unidos, país que ha dado lugar a los estudios pronósticos más importantes, se desconoce la evolución a largo plazo de los pacientes.

8. Objetivos

El objetivo del presente proyecto es mejorar la predicción del grado de funcionalidad de los sujetos que han sufrido un traumatismo cráneoencefálico (TCE) y los costes asociados a su tratamiento, mediante técnicas de *machine learning* aplicadas a variables tanto estáticas como dinámicas determinadas con escalas clínicas específicas de un conjunto de sujetos representativo.

9. Materiales y Metodología

9.1. Muestra

El Servicio de Neurorrehabilitación de Hospitales Vithas cuenta con una historia clínica informatizada donde se han recogido variables clínicas y socio-demográficas de todos los pacientes atendidos durante sus 20 años de actividad asistencial. Estas variables reflejan en distintas escalas estandarizadas y distintos dominios (motor, cognitivo, conductual, comunicación, funcionalidad, etc.) su situación clínica en un momento concreto y su evolución, desde el ingreso hasta el alta. En el momento del análisis el registro contaba con 1087 pacientes que tras sufrir un TCE fueron candidatos a participar en el presente estudio. Los criterios de inclusión/exclusión del estudio se muestran en la Tabla 1.

Criterios de inclusión:	Criterios de exclusión:
Edad ≥ 16 Diagnóstico de TCE Seguimiento en un programa de neurorrehabilitación ≥ 12 meses y haber recibido el alta	Patologías neurológicas concomitantes o previas (ACV, tumor, etc.)

Tabla 1: Criterios de inclusión y exclusión

Tras la aplicación de los criterios de inclusión/exclusión la muestra estuvo compuesta por 801 pacientes que fueron incluidos en un programa de neurorrehabilitación y seguidos durante un período mínimo de 6 meses. De ellos 353 tenían una valoración de seguimiento al año del ingreso.

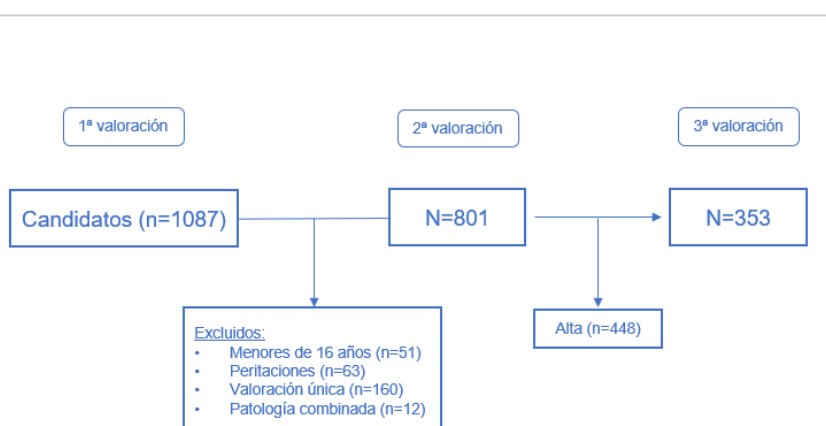


Diagrama 1: Pacientes incluidos en el estudio

9.2. Procedimiento

En base a la literatura existente en relación a los modelos de predicción y a los objetivos de presente estudio se seleccionaron de la historia clínica informatizada aquellas variables con potencial influencia sobre la evolución funcional de los pacientes. Se han definido cuatro niveles o conjuntos de variables para analizar su capacidad predictora sobre la variable objetivo. Considerando que la finalidad de este estudio es el desarrollo de modelos predictivos funcionales se ha tomado como variable objetivo la puntuación de la *Functional Independence Measure (FIM)* en el momento del alta, con sus correspondientes subescalas y estadios.

La escala FIM es una medida comúnmente utilizada en entornos de rehabilitación para evaluar la independencia funcional en las áreas de autocuidado, funcionamiento motor y cognitivo y cuya puntuación total puede ser interpretada como horas de cuidado requerido (Hamilton et al., 1999; *Uniform Data System for Medical Rehabilitation The FIM® Instrument: Its Background, Structure, and Usefulness*, 2012). Incluye 18 elementos, cada uno de los cuales está calificado en una escala tipo Likert de 7 puntos, la cual varía de 1 (asistencia total) a 7 (independencia total) (Anexo 1). Aparte de la puntuación global puede obtenerse un estadio global para el funcionamiento en actividades básicas, el control de esfínteres, la movilidad y la cognición, teniendo en cuenta las puntuaciones jerarquizadas obtenidas en cada uno de los ítems que comprenden la escala. La puntuación total del FIM permite también clasificar el nivel de dependencia como severo (FIM total <72), moderado (FIM total 72-108), leve (FIM total 109-126).

Los cuatro conjuntos de variables predictoras definidos son:

- 1.- Variables socio-demográficas:** sexo (varón/mujer), edad (años), cronicidad (días) y nivel educativo (años escolaridad)
- 2.- Variables relacionadas con la severidad de la lesión:** tipo y severidad de la lesión (clasificación *Traumatic Coma Data Bank*), escalas clínicas como la *Glasgow Coma Scale (GCS)*, la *Disability Rating Scale (DRS)*, la *Glasgow Outcome Scale-Revised (GOS-E)* y la *Differential Outcome Scale (DOS)*; y la duración del período de coma y del período de amnesia postraumática si lo hubiera.
- 3.- Situación funcional al ingreso** definida por la puntuación de la FIM con sus correspondientes estadios y subescalas.
- 4.- Evolución de la situación funcional** definido por la variación de la puntuación FIM entre la valoración inicial y la realizada tras 6 meses de inclusión en un programa de neurorrehabilitación

9.3. Métodos

Los métodos desarrollados en el presente proyecto tienen como objetivo el diseño y programación de algoritmos de *machine learning* para el análisis de variables clínicas, y predicción de la evolución del paciente en su etapa de rehabilitación, con el posterior análisis de costes. Para ello, se ha diseñado un algoritmo capaz de procesar los datos recolectados (variables predictivas), hasta predecir la evolución en la funcionalidad del paciente (variable objetivo). Este algoritmo es flexible a cambios en las variables predictivas, y consta de las siguientes etapas:

- 1. Acondicionamiento de los datos:** como primer paso, no se han tenido en cuenta aquellos pacientes que no tuvieran un seguimiento mínimo de un año y contaran con al menos tres valoraciones (ingreso y seguimiento a los 6 meses y al año de tratamiento), ya que no servirían para estudiar su evolución. A continuación, se han normalizado las variables predictivas, según el tipo de la misma (numérica/texto, continua/categorica). Las variables numéricas son normalizadas mediante el valor máximo observado en la base de datos, acotándolas entre 0 y 1, y las variables categóricas son expresadas en *one-hot encoding*. Aquellos pacientes que presentan valores perdidos en alguna de las variables predictivas quedan descartados. Respecto a la variable objetivo seleccionada, se utiliza la variación del FIM total entre el momento del ingreso y la última valoración del paciente. Finalmente, se realiza una partición *hold-out* a nivel de paciente de la base de datos, creando tres conjuntos: entrenamiento, validación y testeo.
- 2. Elección del modelo:** Una vez obtenidas las variables de entrada al modelo, se realiza una selección de algoritmos de *machine learning* adecuados para resolver tareas de regresión. Para predicciones que requieran únicamente utilizar una valoración del paciente, se seleccionan la regresión lineal (LR), *random forest* (RF), y el perceptrón multi-capas (MLP). En el caso de tomar como entrada varias valoraciones del paciente, se utiliza una red neuronal recurrente que posee la capacidad de codificar la información relevante contenida en series temporales, mediante el uso de unidades *Long-Short Term Memory* (LSTM).

3. **Entrenamiento y optimización:** una vez seleccionadas las variables predictivas y el algoritmo de regresión, se lleva a cabo un proceso de entrenamiento empleando ciertos valores de hiperparámetros y el subconjunto de *training*. Para el algoritmo RF, se optimiza el número de árboles, mientras que para el MLP y LSTM, se optimiza la ratio de aprendizaje, optimizador, número de neuronas, número de capas ocultas y rango de olvido, entre valores típicamente utilizados en tareas de regresión. Como función objetivo, se utiliza la correlación y error cuadrático medio, así como el sobreajuste, observado en el conjunto de validación.
4. **Testeo y obtención de métricas:** una vez se han obtenido los diferentes modelos, se lleva a cabo un proceso de cuantificación de la bondad del mismo mediante el conjunto independiente de testeo. Para el testeo y la obtención de las métricas se empleó una muestra seleccionada de 50 pacientes que no habían participado en el entrenamiento y en la optimización de los modelos. El objetivo de utilizar un subconjunto de datos de estas características es el de obtener métricas fiables y poder extraer conclusiones robustas, no sobre ajustadas al entrenamiento.

Cabe destacar que este algoritmo ha sido desarrollado de forma flexible, permitiendo la elección y cambio en las variables predictivas y objetivo, y siendo capaz de optimizar los modelos de *machine learning* de forma automática.

10. Resultados

10.1. Modelos predictores

A continuación se exponen los resultados obtenidos para cada uno de los conjuntos de variables predictoras definidos.

Modelo 1: Variables demográficas

En este primer conjunto de variables se incluyó la edad, el sexo, los años de escolaridad y la cronicidad definida como el tiempo transcurrido entre la lesión y el ingreso en el programa de neurorrehabilitación. Dado que para este conjunto de variables se emplea una única valoración (inicial) se han testado los modelos que establecen relaciones no lineales (regresión lineal (LR), *random forest* (RF), y el perceptrón multi-capas (MLP), resultando el mejor modelo el perceptrón multi-capas (MLP), con una correlación de 0.50 (Figura 1).




Figura 1: Modelo perceptrón multicapa para las variables demográficas

Modelo 2: Severidad de la lesión

En este segundo conjunto de variables se incluyeron tipo y severidad de la lesión, escalas clínicas como la Glasgow Coma Scale (GCS), la Disability Rating Scale (DRS), la Glasgow Outcome Scale-Revised (GOS-E) y

la Differential Outcome Scale (DOS), y la duración del período de coma y del período de amnesia postraumática si lo hubiera. Se procedió de igual forma que con el anterior conjunto de variables, resultando igualmente el perceptrón multi-capas (MLP) el mejor modelo predictor con una correlación de 0.75 (Figura 2).




Figura 2: Modelo perceptrón multicapa para variables vinculadas a la severidad de la lesión

Modelo 3: Situación funcional al ingreso

En este conjunto de variables que caracterizan la situación funcional del paciente al ingreso se incluyó la puntuación total de la FIM, así como sus correspondientes subescalas y estadios. El modelo que mostró una mayor correlación fue el perceptrón multi-capas (MLP) con una correlación 0.79.

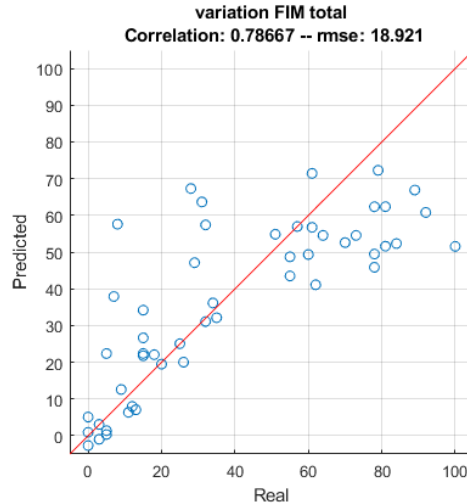


Figura 3: Modelo perceptrón multicapa para variables relacionadas con la situación funcional al ingreso

Modelo 4: Evolución de la situación funcional

Para el último modelo se analizó el valor predictor de la evolución de la situación funcional tras 6 meses de tratamiento neurorrehabilitador sobre la situación funcional al alta. Para esta aproximación final se utilizó una red neuronal recurrente que posee la capacidad de codificar la información relevante contenida en series temporales, mediante el uso de unidades *Long-Short Term Memory* (LSTM). Este modelo mostró una correlación de 0.92 (Figura 4).

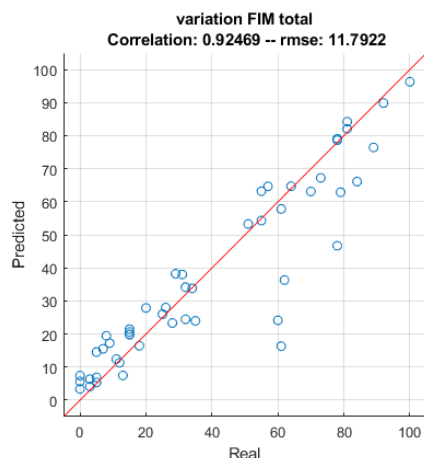


Figura 4: Modelo LSTM que analiza el valor predictor de la evolución funcional tras 6 meses de rehabilitación

La puntuación total del FIM permite la clasificación de la severidad del nivel de dependencia a partir de unos puntos de corte establecidos (Sandhaug et al., 2010). Esta clasificación determina como grave una puntuación total FIM<72; moderado FIM 72-108 y leve FIM>109. En la Figura 5 se refleja el nivel de dependencia real en el momento del alta frente a los valores predichos por cada uno de los modelos.




Figura 5: Nivel de dependencia (FIM) al alta según los diferentes modelos predictivos (n=50)

Tal y como se reflejaban las correlaciones obtenidas para cada uno de los modelos predictores, el modelo 4 es el que muestra un mayor ajuste con la puntuación FIM total obtenida al alta (80%), especialmente para los niveles de dependencia más extremos en la valoración inicial (Tabla 2).

	Modelo 1	Modelo 2	Modelo 3	Modelo 4
Leve (FIM 108-126)	58.1 %	71 %	61.3 %	87.1 %
Moderado (FIM 72-107)	50 %	42.9 %	71.4 %	64.3 %
Grave (FIM 18-71)	80 %	60	0	80
Total	58 % (29/50)	62% (31/50)	58% (29/50)	80% (40/50)

Tabla 2: Porcentaje de pacientes correctamente clasificados según el FIM al alta (n=50)

10.2. Coste-beneficio

La escala FIM permite a su vez una estimación de las horas de cuidado requeridas en función de la puntuación total. Para este estudio se tomaron como referencia los valores descritos previamente en la literatura. Así las horas de cuidado diarias estimadas en función de la puntuación total del FIM se establecieron tal y como se muestra en la Tabla 3 (Quach et al., 2019; *Uniform Data System for Medical Rehabilitation The FIM® Instrument: Its Background, Structure, and Usefulness*, 2012).

Puntuación Total FIM	Horas diarias de cuidado
18-30	16
31-53	6.5
54-71	4.5
72-89	2.5
90-107	1.5
108-119	0.5
120-126	0

Tabla 3: Estimación de horas de cuidado diaria en función de la puntuación total FIM

En la Figura 6 se muestran las horas de cuidado ajustado a la puntuación FIM de acuerdo a la equivalencia anterior.

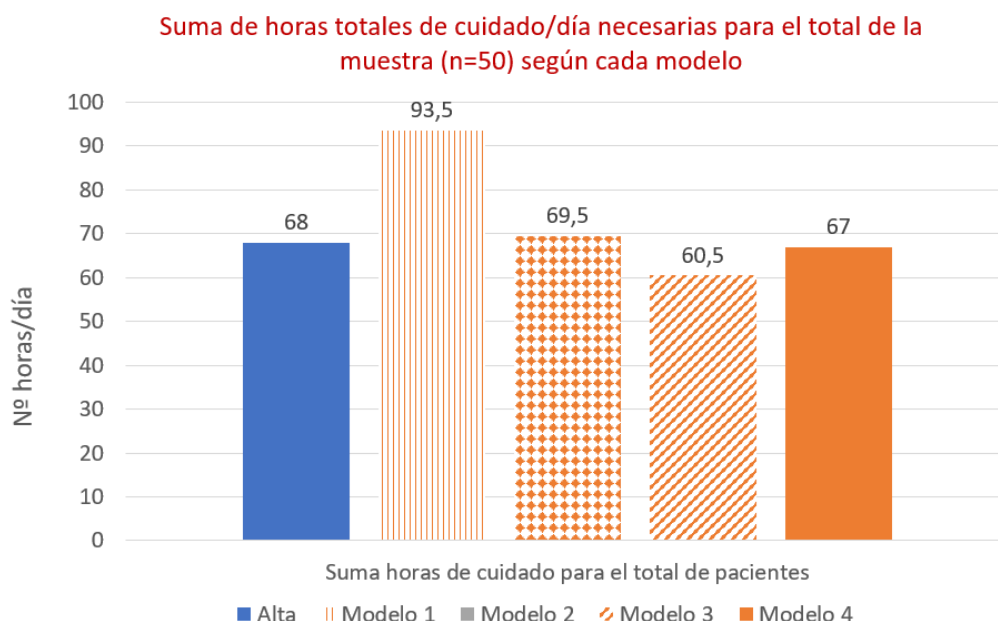


Figura 6: Suma de horas totales de cuidado/día necesarias para el total de la muestra (n=50) según cada modelo

11. Discusión

El presente proyecto establece una serie de aproximaciones de complejidad creciente para predecir el nivel de funcionalidad de pacientes con TCE incluidos en un programa de neurorrehabilitación. Primero, se ha buscado establecer unos resultados base partiendo de modelos utilizados en el estado del arte, los cuales se basan únicamente en el uso de variables estáticas como son las sociodemográficas y la severidad de la lesión. A continuación, se consideran variables que reflejan la situación funcional del paciente en el momento de su inclusión en un programa de neurorrehabilitación. Para estas tres aproximaciones, se entrenan distintos modelos de *machine learning* tales como regresión lineal, *Random Forest*, redes neuronales o *Support Vector Machines*. Finalmente, en una última aproximación, se utilizan las dos primeras valoraciones del paciente, separadas por un período temporal de seis meses, utilizando la evolución de variables dinámicas (situación funcional) mediante redes neuronales LSTM, las cuales tienen la capacidad de analizar series temporales.

En el ámbito de la neurorrehabilitación la estimación pronóstica es un elemento clave para orientar la toma de decisiones clínicas (Gill, 2012), especialmente en el caso de las lesiones más severas y/o los estados alterados de la conciencia donde el pronóstico puede influir en el acceso a recursos o a intervenciones terapéuticas e incluso a decisiones vinculadas al final de la vida (Demertzi et al., 2011). Pese a su relevancia clínica, la heterogeneidad que caracteriza a los TCE hace que el desarrollo y la validación de modelos predictores tempranos y precisos continúe siendo un reto. La estandarización de la terminología diagnóstica, de la valoración clínica (escalas y pruebas diagnósticas) y del abordaje terapéutico, junto a los avances en los modelos estadísticos han facilitado el análisis de los datos ofreciendo nuevas oportunidades para un enfoque basado en la evidencia.

En las últimas décadas se han desarrollado y validado numerosos estudios pronósticos para la funcionalidad de los TCE moderados-severos. Estos estudios han incorporado diferentes modelos de predicción que han sido aplicados en diferentes poblaciones, lo que dificulta notablemente su comparación. Las conclusiones extraídas ponen de manifiesto una serie de limitaciones que dificultan la obtención de modelos predictores precisos. En primer lugar, las escalas de discapacidad suelen ser muy globales y no tienen en cuenta el origen de la discapacidad. Sin embargo, los pacientes con TCE pueden presentar un conjunto muy heterogéneo de secuelas y la transferencia del nivel de discapacidad a la funcionalidad de los pacientes no es obvia. Distintos niveles de funcionalidad podrían estar enmascarados dentro del mismo nivel de discapacidad. En segundo lugar, la mayoría de los estudios no incluyen variables dinámicas en los análisis como el estado de las estructuras neurológicas, la condición motora, cognitiva o conductual, el grado de funcionalidad, etc. La progresión de los distintos déficits tras un TCE puede constituir, en sí misma, una variable más a tener en cuenta en el pronóstico de los individuos. Sin embargo, estas variables suelen ser sistemáticamente descartadas, entre otras cosas, debido a la falta de datos de seguimiento de los pacientes. Y finalmente, la metodología de los estudios se ha limitado a la creación de modelos predictivos de regresión mediante estadística inferencial. En este sentido, cabe destacar que la evolución que las técnicas de *machine learning* han experimentado en los últimos años ha permitido la modelización de relaciones complejas en grandes volúmenes de datos.

Superando las limitaciones descritas anteriormente, el presente estudio analiza a través de distintas aproximaciones o modelos multivariantes el valor pronóstico sobre el nivel de funcionalidad de pacientes con TCE incluidos en un programa de neurorrehabilitación empleando técnicas de *machine learning*. Los modelos analizados fueron definidos en base a estudios previos y como variable objetivo se tomó la puntuación del *Functional Independence Measure* con el fin de cuantificar el nivel de funcionalidad de los afectados y, en base a ella, la necesidad de cuidados y asistencia. Frente a estudios previos que emplean escalas más globales de discapacidad como la GOS-E, la FIM aporta información precisa y de mayor relevancia práctica sobre la funcionalidad y participación del afectado, independientemente de su nivel de discapacidad, y sobre la necesidad de cuidados y asistencia. En neurorrehabilitación, a diferencia de otras disciplinas médicas, el objetivo no está centrado en la enfermedad sino en la recuperación de aquellos aspectos relacionados con la funcionalidad y la participación que caracterizan como seres humanos únicos a aquellos que sobreviven. Por ello el cambio de paradigma de los modelos de predicción hacia aspectos funcionales resulta de vital importancia, especialmente en el caso de los TCE que generan una gran discapacidad en personas jóvenes que se encontraban en pleno desarrollo de su proyecto vital. La mayor parte de los modelos predictores utilizados hasta la fecha basan sus resultados en variables dicotomizadas (favorable & desfavorable), disminuyendo significativamente su capacidad de predicción cuando se contemplan niveles de funcionalidad intermedios. Choi and Barnes (1996) compararon la precisión de diversos modelos de predicción usando la *Traumatic Coma Data Bank* (TCDB). Este grupo demostró una precisión predictiva con un límite superior entre 75-80% en TCE severos en base a los datos disponibles en el momento de la admisión. Pese a que existe una adecuada fiabilidad en la predicción de valores extremos (favorables & desfavorables), esta precisión disminuye drásticamente al 50-60% cuando se consideran resultados intermedios. En esta misma línea, los dos modelos clásicos de mayor relevancia clínica como son el IMPACT y el CRASH dicotomizan los resultados en función del GOS-E a los 6 meses como mortalidad (GOS-E1) versus supervivencia (GOS-E 2-8) y desfavorables (GOS-E 1-4) o favorables (GOS-E 5-8) (Roozenbeek et al., 2012). A nivel clínico esta dicotomización de los resultados carece de la especificidad suficiente para poder determinar con precisión el nivel de funcionalidad y participación de los sujetos e inferir a partir de esta información las necesidades requeridas para su atención y posible integración social.

Una vez definida la variable objetivo se plantearon distintas aproximaciones definiendo cuatro conjuntos de variables predictoras. La primera aproximación incluyó variables sociodemográficas que habían demostrado previamente su valor pronóstico como son la edad, el sexo, el nivel de escolaridad y la cronicidad (Bonnelle et al., 2011). El mejor de los algoritmos testados fue el perceptrón multicapa obteniendo una correlación del 0.50. Este valor es semejante a los obtenidos por otros modelos que emplean estas variables cuando se consideran resultados no dicotomizados (Hukkelhoven et al., 2005). La segunda de las aproximaciones incluyó un conjunto de variables vinculadas a la severidad de la lesión como son *Glasgow Coma Scale* (GCS), la *Disability Rating Scale* (DRS), la *Glasgow Outcome Scale-Revised* (GOS-E), la *Differential Outcome Scale* (DOS), la duración del período de coma y del período de amnesia postraumática si lo hubiera. De nuevo el algoritmo más eficiente fue el perceptrón multicapa. Frente a la modelo anterior se observa un notable aumento de su capacidad predictora alcanzando una correlación del 0.75 que podría estar explicada por la inclusión de variables dinámicas como son el tiempo en coma y la duración del período de amnesia postraumática. Una reciente revisión sistemática (Huijben et al., 2019) señala que la mayor parte de los predictores empleados en los modelos analizados se basan en los datos obtenidos en las primeras 24 horas tras la lesión porque una predicción temprana permite ajustar expectativas con los familiares y ayudar a decidir su inclusión temprana en programas de rehabilitación. Sin embargo, las variables predictivas de los dos principales modelos (IMPACT y CRASH) sólo explican alrededor del 35% de la varianza del resultado y aumentar la complejidad de los modelos con otras variables recogidas de forma temprana no implica mejoras sustanciales. Estos datos ponen de manifiesto la necesidad de considerar la inclusión de variables dinámicas para aumentar la precisión de los modelos. Limitarse a variables estáticas puede generar factores de confusión ya que la gravedad de la situación clínica y la presencia de complicaciones asociadas puede influir en las variables consideradas pronósticas y puede limitar la inclusión en programas de rehabilitación que podrían generar mejoras sustanciales en la funcionalidad de los afectados una vez superada la situación crítica inicial.

En esta línea de inclusión de variables dinámicas para la tercera de nuestras aproximaciones se consideró como variable predictora la situación funcional del paciente en el momento de su ingreso en el programa de neurorrehabilitación definida por la puntuación total del FIM, sus estadios y sus subescalas. Tras la aplicación del algoritmo perceptrón multicapa se obtuvo una correlación de 0.79. Como vemos la inclusión de variables dinámicas aumenta la capacidad predictiva de los modelos. Finalmente el modelo con mayor precisión se obtuvo cuando se analizó el valor predictor de la evolución de la situación funcional del paciente tras ser incluido en un programa de neurorrehabilitación. A los seis meses de su inclusión el modelo permite predecir con una elevada precisión (0.92) el nivel de funcionalidad y participación del afectado a partir de un algoritmo de redes neurales. El TCE es una patología heterogénea con una elevada variabilidad en el curso de la evolución, por lo que añadir nueva información dinámica o incluir factores que predigan la respuesta al tratamiento podría ser una interesante alternativa para mejorar el valor predictivo de los modelos. Así mismo, una predicción ajustada del nivel funcional permitirá una planificación realista de las necesidades de asistencia y cuidados al alta, mejorando la calidad de vida de los pacientes y reduciendo la sobrecarga de los cuidadores.

12. Conclusiones

El objetivo del presente estudio es el desarrollo de un modelo predictor del grado de funcionalidad de sujetos que han sufrido un TCE tras ser incluidos en un programa de neurorrehabilitación. Para ello se testaron una serie de modelos de complejidad creciente con variables predictoras estáticas y dinámicas mediante técnicas de *machine learning* y tomando como variable objetivo la puntuación del *Functional Independence Measure*. El modelo que presentó un mayor nivel de ajuste fue el que analizó la capacidad predictora de la evolución de la situación funcional del paciente tras 6 meses de inclusión en un programa de neurorrehabilitación. Una estimación precisa de la recuperación funcional permite una planificación ajustada de las necesidades de cuidado y asistencia al alta, mejorando así la calidad de vida de los pacientes y sus cuidadores.

Frente a los modelos clásicos que se basan en variables predictoras estáticas recogidas de forma temprana, la inclusión de variables dinámicas aumenta el valor predictivo de los modelos. Estos resultados tienen una marcada relevancia clínica ya que ponen de manifiesto que el mayor valor predictor funcional viene determinado por su respuesta a la intervención clínica en un programa de neurorrehabilitación, más allá de las variables sociodemográficas (edad, sexo, etc.), la severidad de la lesión y la situación funcional del paciente en el momento del ingreso.

13. Bibliografía

- Bates, D. (2001). The prognosis of medical coma. *Journal of Neurology Neurosurgery and Psychiatry*, 71(SUPPL. 1). https://doi.org/10.1136/jnnp.71.suppl_1.i20
- Bonnelle, V., Leech, R., Kinnunen, K. M., Ham, T. E., Beckmann, C. F., de Boissezon, X., Greenwood, R. J., & Sharp, D. J. (2011). Default mode network connectivity predicts sustained attention deficits after traumatic brain injury. *Journal of Neuroscience*, 31(38), 13442–13451. <https://doi.org/10.1523/JNEUROSCI.1163-11.2011>
- Bushnik, T., Hanks, R. A., Kreutzer, J., & Rosenthal, M. (2003). Etiology of traumatic brain injury: Characterization of differential outcomes up to 1 year postinjury. *Archives of Physical Medicine and Rehabilitation*, 84(2), 255–262. <https://doi.org/10.1053/apmr.2003.50092>
- Claassen, J., & Hansen, H. C. (2001). Early recovery after closed traumatic head injury: Somatosensory evoked potentials and clinical findings. *Critical Care Medicine*, 29(3). <https://doi.org/10.1097/00003246-200103000-00005>
- Demertzi, A., Ledoux, D., Bruno, M. A., Vanhaudenhuyse, A., Gosseries, O., Soddu, A., Schnakers, C., Moonen, G., & Laureys, S. (2011). Attitudes towards end-of-life issues in disorders of consciousness: A European survey. *Journal of Neurology*, 258(6), 1058–1065. <https://doi.org/10.1007/s00415-010-5882-z>
- G, F., P, F., L, S., I, G., M, S., J, T., S, B., B, Y., & Z, G. (1999). Apolipoprotein E-epsilon4 genotype predicts a poor outcome in survivors of traumatic brain injury. In *Neurology* (Vol. 52, Issue 2).
- Giacino, J. T., Sherer, M., Christoforou, A., Maurer-Karattup, P., Hammond, F. M., Long, D., & Bagiella, E. (2020). Behavioral Recovery and Early Decision Making in Patients with Prolonged Disturbance in Consciousness after Traumatic Brain Injury. *Journal of Neurotrauma*. <https://doi.org/10.1089/neu.2019.6429>
- Gill, T. M. (2012). The central role of prognosis in clinical decision making. In *JAMA - Journal of the American Medical Association* (Vol. 307, Issue 2, pp. 199–200). <https://doi.org/10.1001/jama.2011.1992>
- Girard, D., Brown, J., Burnett-Stolnack, M., Hashimoto, N., Hier-Wellmer, S., Perlman, O. Z., & Seigerman, C. (1996). The relationship of neuropsychological status and productive outcomes following traumatic brain injury. *Brain Injury*, 10(9), 663–676. <https://doi.org/10.1080/026990596124089>
- Hall, K. M., Bushnik, T., Laksic-Kazacic, B., Wright, J., & Cantagallo, A. (2001). Assessing traumatic brain injury outcome measures for long-term follow-up of community-based individuals. *Archives of Physical Medicine and Rehabilitation*, 82(3). <https://doi.org/10.1053/apmr.2001.21525>
- Hamilton, B. B., Deutsch, A., Russell, C., Fiedler, R. C., & Granger, C. v. (1999). Relation of disability costs to function: Spinal cord injury. *Archives of Physical Medicine and Rehabilitation*, 80(4). [https://doi.org/10.1016/S0003-9993\(99\)90274-5](https://doi.org/10.1016/S0003-9993(99)90274-5)
- Hoofien, D., Vakil, E., Gilboa, A., Donovan, P. J., & Barak, O. (2002). Comparison of the predictive power of socio-economic variables, severity of injury and age on long-term outcome of traumatic brain injury: Sample-specific variables versus factors as predictors. *Brain Injury*, 16(1). <https://doi.org/10.1080/02699050110088227>
- Huijben, J. A., Wiegers, E. J. A., de Keizer, N. F., Maas, A. I. R., Menon, D., Ercole, A., Citerio, G., Lecky, F., Wilson, L., Cnossen, M. C., Polinder, S., Steyerberg, E. W., van der Jagt, M., Lingsma, H. F., Aries, M., Badenes, R., Beishuizen, A., Bilotta, F., Chieragato, A., ... Vos, P. E. (2019). Development of a quality

- indicator set to measure and improve quality of ICU care for patients with traumatic brain injury. *Critical Care*, 23(1). <https://doi.org/10.1186/s13054-019-2377-x>
- Hukkelhoven, C. W. P. M., Steyerberg, E. W., Habbema, J. D. F., Farace, E., Marmarou, A., Murray, G. D., Marshall, L. F., & Maas, A. I. R. (2005). Predicting outcome after traumatic brain injury: Development and validation of a prognostic score based on admission characteristics. *Journal of Neurotrauma*, 22(10). <https://doi.org/10.1089/neu.2005.22.1025>
- Hukkelhoven, C. W. P. M., Steyerberg, E. W., Rampen, A. J. J., Farace, E., Habbema, J. D. F., Marshall, L. F., Murray, G. D., & Maas, A. I. R. (2003). Patient age and outcome following severe traumatic brain injury: An analysis of 5600 patients. *Journal of Neurosurgery*, 99(4). <https://doi.org/10.3171/jns.2003.99.4.0666>
- Leach, L. R., Frank, R. G., Bouman, D. E., & Farmer, J. (1994). Family functioning, social support and depression after traumatic brain injury. *Brain Injury*, 8(7). <https://doi.org/10.3109/02699059409151012>
- Marshall, L. F., Toole, B. M., & Bowers, S. A. (1983). The National Traumatic Coma Data Bank. Part 2. Patients who talk and deteriorate: Implications for treatment. *Journal of Neurosurgery*, 59(2). <https://doi.org/10.3171/jns.1983.59.2.0285>
- Quach, N. T., Ehsanian, R., Dirlikov, B., Sechrist, S., Mohole, J., McKenna, S., Isaac, L., & Duong, T. T. (2019). Burden of care implications and association of intracranial hypertension with extremely severe post-traumatic amnesia after traumatic brain injury: A 5-year retrospective longitudinal study. *Frontiers in Neurology*, 10(JAN). <https://doi.org/10.3389/fneur.2019.00034>
- Roozenbeek, B., Lingsma, H. F., Lecky, F. E., Lu, J., Weir, J., Butcher, I., McHugh, G. S., Murray, G. D., Perel, P., Maas, A. I., & Steyerberg, E. W. (2012). Prediction of outcome after moderate and severe traumatic brain injury: External validation of the International Mission on Prognosis and Analysis of Clinical Trials (IMPACT) and Corticoid Randomisation after Significant Head injury (CRASH) prognostic models. *Critical Care Medicine*, 40(5). <https://doi.org/10.1097/CCM.0b013e31824519ce>
- Sandhaug, M., Andelic, N., Vatne, A., Seiler, S., & Mygland, A. (2010). Functional level during sub-acute rehabilitation after traumatic brain injury: Course and predictors of outcome. *Brain Injury*, 24(5). <https://doi.org/10.3109/02699051003652849>
- Sherer, M., Bergloff, P., Walter, H., & Nick, T. G. (1999). Contribution of functional ratings to prediction of longterm employment outcome after traumatic brain injury. *Brain Injury*, 13(12). <https://doi.org/10.1080/026990599120981>
- Siegel, J. H., Gens, D. R., Mamantov, T., Geisler, F. H., Goodarzi, S., & Mackenzie, E. J. (1991). Effect of associated injuries and blood volume replacement on death, rehabilitation needs, and disability in blunt traumatic brain injury. *Critical Care Medicine*, 19(10). <https://doi.org/10.1097/00003246-199110000-00007>
- Susman, M., DiRusso, S. M., Sullivan, T., Risucci, D., Nealon, P., Cuff, S., & Benzil, D. (2002). Traumatic brain injury in the elderly: Increased mortality and worse functional outcome at discharge despite lower injury severity. *Journal of Trauma*, 53(2). <https://doi.org/10.1097/00005373-200208000-00004>
- Teasell, R., Bayona, N., Marshall, S., Cullen, N., Bayley, M., Chundamala, J., Villamere, J., Mackie, D., Rees, L., Hartridge, C., Lippert, C., Hilditch, M., Welch-West, P., Weiser, M., Ferri, C., McCabe, P., McCormick, A., Aubut, J. A., Comper, P., ... Tu, L. (2007). A systematic review of the rehabilitation of moderate to severe acquired brain injuries. In *Brain Injury*. <https://doi.org/10.1080/02699050701201524>

Uniform Data System for Medical Rehabilitation The FIM® Instrument: Its Background, Structure, and Usefulness. (2012).

www.udsmr.org/Documents/The_FIM_Instrument_Background_Structure_and_Usefulness.pdf

Wang, J. Y., Bakhadirov, K., Abdi, H., Devous, M. D., Marquez De La Plata, C. D., Moore, C., Madden, C. J., & Diaz-Arrastia, R. (2011). Longitudinal changes of structural connectivity in traumatic axonal injury. *Neurology*. <https://doi.org/10.1212/WNL.0b013e31822c61d7>

Wilson, J. T. L., Pettigrew, L. E. L., & Teasdale, G. M. (2000). Emotional and cognitive consequences of head injury in relation to the Glasgow outcome scale. *Journal of Neurology Neurosurgery and Psychiatry*, *69*(2). <https://doi.org/10.1136/jnnp.69.2.204>

14.Anexos

ESCALA MOTORA (EM)	
Actividades Básicas	
1. Alimentación	
2. Deglución (L)	
3. Aseo	
4. Baño	
5. Vestido parte superior	
6. Vestido parte inferior	
7. WC	
Control de esfínteres	
8 ^V Vesical-nivel asistencia	
8 ^V Vesical-frecuencia de accidentes	
	Usa el peor
9 ^I Intestinal-nivel asistencia	
9 ^I Intestinal-frecuencia de accidentes	
	Usa el peor
Movilidad	
10. Transferencia cama-silla	
11. Transferencia baño	
12. Transferencia bañera-ducha	
13. Transferencia vehículo	
14 ^L Locomoción Marcha	
14 ^S Locomoción Silla de ruedas	
14 Modo preferido locomoción	
15. Escaleras	
16 Movilidad en comunidad*1	
Estadio básicas:	
Estadio esfínteres:	
Estadio movilidad:	

FIM
FAM

*1 Modo Preferido: C-coche, T-taxi, P-Transporte público

FIM							
Estado	1	2	3	4	5	6	7
ABVD							
Alimentación	1	3	4	5	6	6	7
Aseo	1	3	4	5	5	6	7
Baño	1	1	2	3	5	5	7
Vestido sup	1	2	3	4	5	6	7
Vestido Infer	1	1	2	3	4	6	7
WC	1	1	2	3	5	6	7
Control de esfínteres							
Vesical	1	1	3	4	5	6	7
Intestinal	1	3	3	4	5	6	7
Movilidad							
Trans cama-silla	1	3	4	5	5	6	7
Trans baño	1	3	4	5	5	6	7
Trans bañera-ducha	1	1	3	4	5	6	7
Modo locomoción	1	1	2	4	5	6	7
Escaleras	1	1	1	1	4	5	7
Escala Cognitiva							
Comprensión	1	3	4	5	5	6	7
Expresión	1	2	3	4	5	6	7
Interacción social	1	2	3	4	5	6	7
Resol problemas	1	1	2	3	4	5	7
Memoria	1	1	2	3	5	6	7

ESCALA COGNITIVA (EC)	
Comunicación (L)	
17. Comprensión	
18. Expresión	
19. Lectura	
20. Escritura	
21. Inteligibilidad	
Interacción psicosocial (NP)	
22. Interacción social	
23. Estado emocional	
24. Conciencia enfermedad	
25. Actividades de ocio	
Funciones cognitivas (NP)	
26. Resolución de problemas	
27. Memoria	
28. Orientación	
29. Concentración	
30. Conciencia riesgo	
Estadio Cognitiva:	

ACTIVIDADES EXTENDIDAS DE VIDA DIARIA (AEVD)	
31. Preparación comida	
32. Colada	
33. Limpieza doméstica	
34. Compras	
35. Economía familiar	
36. Trabajo/Educación (NP)	

FAM	
Nivel 7: Sin ayuda de una persona	
No ayuda de otra personas, NO ayudas técnicas	
Nivel 6: Sin ayuda de una persona	
No ayuda de otra personas, SI ayudas técnicas	
Nivel 5: Supervisión/Preparación/ No contacto físico	
No ayuda, pero si adaptación o guía verbal	
Nivel 4: Ayuda mínima de una persona	
Ayuda de contacto para completar tarea SOLO +75% de la tarea	
Nivel 3: Ayuda moderada de una persona	
Realiza solo más del 50% de la tarea	
Nivel 2: Ayuda máxima de una persona	
Realiza menos del 50% de la tarea pero contribuye	
Nivel 1: Ayuda total de una persona	
Es Incapaz o hace muy poco (-25% de la tarea)	

Anexo 1: Medida de Independencia Funcional FIM-FAM