

# Aplicación de la analítica predictiva en el modelo de gestión de contingencia común

C. A. Martínez Fernández, P. Teixidó Martínez, O. Puig Palau, A. Álvarez Encinas, M. Serra Robert, N. Grandal Vila, M. Ramírez Tamez

Mutua Universal Toledo

## Correspondencia:

Dr. Carlos Alberto Martínez Fernández

Correo electrónico: cmartinez@mutuauniversal.net

Recibido el 13 de marzo de 2023

Aceptado el 5 de abril de 2023

Disponible en Internet: junio de 2023

## RESUMEN

**Objetivo:** el objetivo del estudio fue examinar la puesta en marcha de un modelo de analítica predictiva en pacientes en situación de incapacidad temporal (IT) por contingencia común (CC), utilizando los valores predictivos “días de IT” y “perfil alta”, para personalizar las acciones, llevarlas a cabo en el momento más oportuno y ver si mejoraban los indicadores de gestión.

**Método:** estudio observacional transversal descriptivo, realizándose una prueba piloto del modelo predictivo en 7 centros asistenciales, durante un periodo de 3 meses (abril-junio 2022).

**Resultados:** durante el periodo del piloto en los 7 centros participantes, se realizaron un 64% de propuestas de alta, de las cuales el 75% finalizaron en alta laboral. Se logró una reducción del 2,5% en la duración media de los procesos de baja y se observó un leve incremento del 0,19% en la prevalencia, que fue inferior al observado en el resto de nuestra mutua durante el mismo periodo.

**Conclusiones:** la aplicación del modelo predictivo permitió priorizar la gestión y personalizar las acciones de los procesos de IT por CC, evidenciándose una mejora en los indicadores de gestión.

**Relevancia en la gestión:** la aplicación de un modelo predictivo de este tipo puede mejorar la eficacia y la eficiencia en la gestión de la IT por CC, por concentrar los recursos en un menor

## ABSTRACT

**Application of a predictive analytics model in the management of non-work-related injury and illness**

**Objective:** the aim of this study was to pilot and evaluate a predictive analytics model for the management of patients with temporary incapacity for work due to non-work-related injury or illness. The predictive score based on ‘estimated days of temporary incapacity’ and ‘likelihood of a return to work’ was used to identify more individualized and timely actions, and we examined whether this led to an improvement in case indicators.

**Method:** descriptive observational cross-sectional study, in which the predictive analytics model was piloted over a 3-month period (April-June 2022) in 7 clinical centres.

**Results:** during the pilot period in the 7 participating centres, the predictive model identified 64% of patients as being fit for work, of whom 75% returned to their regular employment. The mean duration of absence from work decreased by 2.5%, with an increase in the prevalence indicator (0.19%) that was below the value for our organization as a whole across the same period.

**Conclusions:** application of the predictive model enabled prioritization and a more individualized approach to patients with temporary incapacity for work due to non-work-related injury or illness, leading to an improvement in case indicators.

Trabajo presentado en el Congreso Nacional SETLA 2022 en formato póster recibiendo el premio al mejor cartel científico SETLA.



<https://doi.org/10.24129/j.retla.06111.fs2303001>

© 2023 Sociedad Española de Traumatología Laboral. Publicado por Imaidea Interactiva en FONDOSCIENCE® ([www.fondoscience.com](http://www.fondoscience.com)). Este es un artículo Open Access bajo la licencia CC BY-NC-ND ([www.creativecommons.org/licenses/by-nc-nd/4.0/](http://www.creativecommons.org/licenses/by-nc-nd/4.0/)).

número de procesos a gestionar, redundando en un potencial impacto económico.

**Palabras clave:** Analítica predictiva. Contingencia común. Incapacidad temporal. *Machine learning*.

**Relevance to practice:** application of a predictive model of this kind enables the targeting of resources, thus contributing to improved efficiency and effectiveness in the management of temporary incapacity for work due to non-work-related injury or illness, and leading potentially to cost savings for healthcare providers.

**Key words:** Non-work-related injury and illness. Machine learning. Predictive analytics. Temporary incapacity for work.

## Introducción

En el segundo trimestre de 2022 el absentismo provocó en España la pérdida de un 6,2% de las horas de actividad laboral; de ellas, el 4,8% fueron por absentismo por incapacidad temporal (IT)<sup>(1)</sup>. En los datos disponibles en las estadísticas oficiales de la Seguridad Social se observa un incremento del promedio mensual de procesos de baja por contingencia común (CC) en un 21,60%, lo que implica un índice de incidencia de 28,86, un 29,21% superior al de 2021<sup>(2)</sup>. Además, de la revisión de los indicadores de gestión en 2022 en el conjunto de las mutuas de colaboración con la Seguridad Social (MCSS) se ha producido un aumento interanual del índice de prevalencia superior al 11% (ratio que monitoriza el número de procesos pendientes de alta en función de la población protegida)<sup>(3)</sup>.

El Real Decreto 625/2014, de 18 de julio, por el que se regulan determinados aspectos de la gestión y el control de los procesos por incapacidad temporal, en los primeros 365 días de su duración, modifica algunos de los aspectos para realizar el control y el seguimiento de los pacientes en situación de IT por CC desde las MCSS. Como consecuencia del histórico de este control y seguimiento, se generan en esta mutua una ingente cantidad de datos de salud y de otra índole (económicos, geográficos, etc.) del paciente y de su entorno. Así pues, en esta mutua se dispone de más de un millón de datos actuales e históricos registrados en los sistemas informáticos en relación con estos procesos que incluyen más de 180 variables estructuradas.

La analítica predictiva es el análisis basado en el uso de estos datos utilizando algoritmos estadísticos y técnicas de *machine learning* (aprendizaje continuo), prediciendo patrones con los que poder anticipar cuál es el momento más adecuado para realizar la gestión de los procesos asistenciales. Utilizando algoritmos estadísticos y técnicas de *machine learning* se puede crear un modelo que sea

capaz de predecir un valor de salida después de haber sido entrenado. En el manejo del *machine learning* es conveniente seguir un proceso de revisión si se quieren obtener buenos resultados, con ello conseguimos optimizar el uso del tiempo y conseguir una reorientación en el supuesto de no alcanzar los resultados esperados<sup>(4)</sup> (Figura 1).

El objetivo del estudio consistió en examinar la puesta en marcha de un modelo de analítica predictiva en pacientes en situación de IT por CC, utilizando los valores predictivos “días de IT” y “perfil alta” (grado de que una propuesta de alta tenga éxito), para personalizar las acciones, llevarlas a cabo en el momento más oportuno y ver si mejoran los indicadores de gestión. Se plantearon como objetivos secundarios evaluar el impacto de los valores predictivos en los indicadores de gestión habituales con el fin de conocer la eficacia y la eficiencia del modelo predictivo (duración media de las altas, número de procesos de alta con una propuesta de alta dirigida a inspección médica realizada desde la mutua, éxito de estas, prevalencia).

## Material y métodos

Se realizó un estudio observacional transversal descriptivo mediante una prueba piloto implementando el modelo

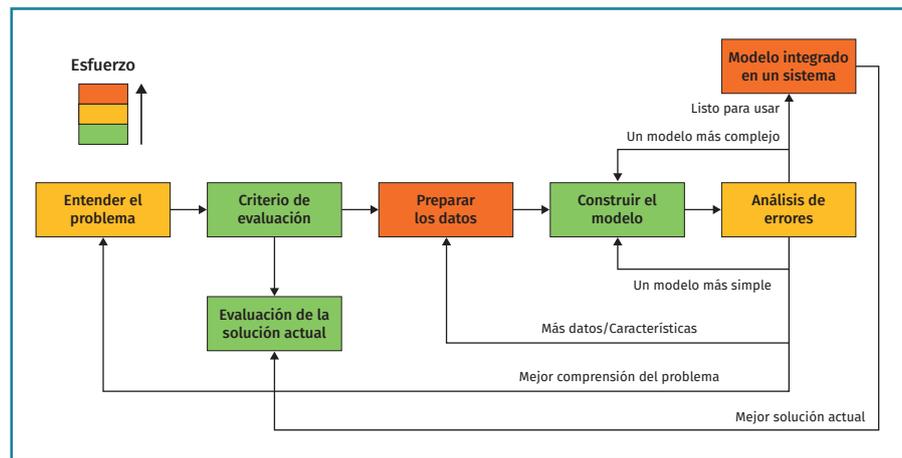


Figura 1. Variables específicas de contingencia común. Fuente: iartificial.net.

predictivo de aprendizaje continuo en la gestión asistencial de las bajas por CC.

Mediante muestreo por conveniencia se incluyeron 7 centros asistenciales (CA) para el análisis: Asturias (Avilés, Gijón, Oviedo), Cuenca, Murcia, Sevilla y Zaragoza. El periodo de estudio fue de 3 meses (abril-junio 2022).

### Criterios de inclusión

Todos los procesos en situación de IT por CC que se encontraban entre 15 y 200 días de duración de IT de los CA en estudio, con una desviación sobre la duración media prevista entre un 80 y un 150%, junto con el valor “perfil alta”.

### Criterios de exclusión

Todos los procesos asistenciales próximos al agotamiento de plazo de IT, en concreto aquellos que tenían más de 300 días de duración de la IT y los de menos de 15 días de IT.

Aplicando los criterios de inclusión se seleccionaron 1.600 episodios de CC que representaban alrededor de un 10% del total de los procesos en IT de los CA incluidos en el estudio.

Las variables principales del estudio fueron cuantitativas y sus categorías las siguientes:

- **Variables específicas de la CC:** porcentaje de procesos de alta con una propuesta de alta dirigida a inspección médica realizada desde la mutua, porcentaje del éxito de las propuestas de alta emitidas desde la mutua y duración media de las altas de los procesos asistenciales por CC.

- **Variables generales de gestión:** índice de prevalencia de los CA incluidos en la prueba piloto.

Se realizó un análisis descriptivo de los datos calculando para cada una de las variables sus porcentajes. La herramienta utilizada para la explotación de los datos y la consecución de los resultados fue Excel.

## Resultados

### Variables específicas de la contingencia común

Se seleccionaron un total de 1.600 procesos de baja de los CA en análisis representado alrededor de un 10% del total de ellos. De estos procesos baja se realizaron a un 63,50% propuestas de alta, que representa una mejora del 18,1% respecto a los datos globales de los centros piloto y del 50,7% respecto al resto de los centros de la mutua.

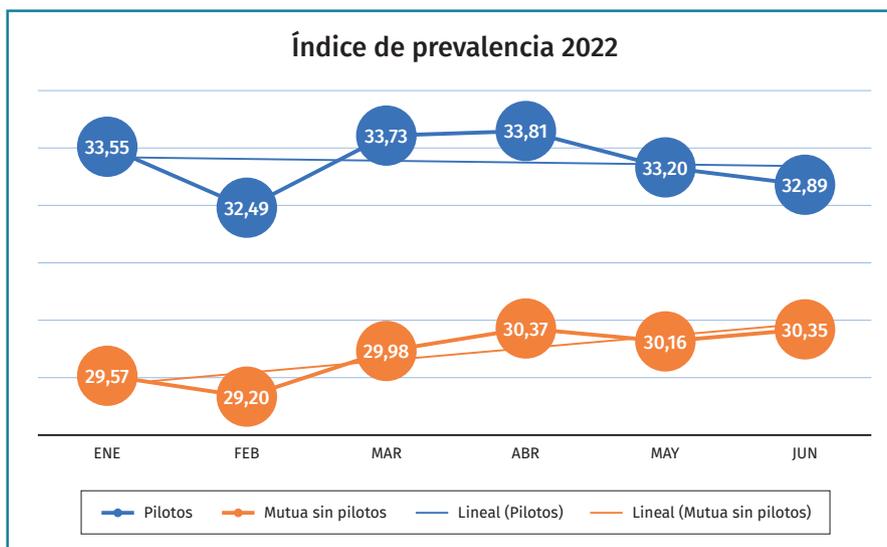
De las propuestas de alta realizadas, el 74,97% finalizaron en alta laboral emitida por el médico de cabecera, evidenciándose una mejora del 11,4% respecto a los CA del piloto y del 21,7% respecto al resto de la mutua.

La duración media de los procesos asistenciales con un alta ya emitida fue un 3,4% inferior a la de los CA del piloto y un 2,5% inferior a la del resto de la mutua (Tabla 1).

**Tabla 1. Variables específicas de contingencia común**

Indicador	Casos piloto	Centros piloto	% Var vs. piloto	Mutua sin centros piloto	% Var vs. piloto
N.º altas	978	3.562	-	37.766	-
% altas con propuestas	63,50%	53,76%	18,1%	42,15%	50,7%
% éxito propuestas	74,97%	67,29%	11,4%	61,60%	21,7%
DM altas*	77,71	80,44	-3,4%	79,67	-2,5%

\* Se eliminan del cálculo casos de más de 300 días de incapacidad temporal previos al inicio del piloto  
Fuente: datos internos mutua



**Figura 2. Variables generales de gestión.** Fuente: datos internos mutua.

## VARIABLES GENERALES DE GESTIÓN

De la evaluación de la prevalencia media trimestral (comparativa 1.º trimestre-2.º trimestre de 2022) se observó que el porcentaje de prevalencia en los CA en análisis se incrementó levemente en un 0,19%, siendo este incremento menor en comparación con el 2,40% del resto de la mutua.

En la gráfica se apreció una tendencia descendente de la prevalencia mensual durante el segundo trimestre de 2022 de los CA participantes en la prueba piloto; en cambio la tendencia fue ascendente para el resto de los CA de la mutua (Figura 2).

## DISCUSIÓN

La utilización de analítica predictiva no es algo nuevo en medicina. En la actualidad, gracias a la combinación de diferentes técnicas de aprendizaje continuo, utilizando datos clínicos estructurados y no estructurados, obtenemos en tiempo real un valor predictivo para un problema similar<sup>(5)</sup>. La explotación de los datos almacenados en las historias clínicas ha permitido un cambio de enfoque en relación con la gestión de estos registros con una clara intención, mejorar el proceso de la toma de decisiones. Los modelos predictivos permiten a los gestores planificar una estrategia y unos objetivos más adecuados. Y esta necesidad, en el contexto del control y el seguimiento por contingencias comunes, surge del entorno actual en donde el absentismo está creciendo año tras año. De la revisión de los indicadores de gestión en el conjunto de las MCSS se produjo en 2022 un aumento interanual del índice de prevalencia superior al 11% (ratio que monitoriza el número de procesos pendientes de alta en función de la población protegida)<sup>(9)</sup>.

Las consecuencias económicas de este crecimiento son de alto impacto en el sistema; por este motivo, se actualizó la regulación mediante el Real Decreto 625/2014, de 18 de julio, para que las MCSS tuvieran más herramientas como responsables del control y el seguimiento de las bajas por CC. Lo cierto es que el volumen de bajas a gestionar es de tal magnitud que se hace inmanejable por parte de todos los actores del sistema (servicios públicos de salud, MCSS e Instituto Nacional de la Seguridad Social –INSS–).

La analítica predictiva es el análisis basado en el uso de estos datos utilizando algoritmos estadísticos y técnicas de ma-

chine learning (aprendizaje continuo), prediciendo patrones con los que poder anticipar cuál es el momento más adecuado para realizar la gestión de los procesos asistenciales.

En este estudio se utilizaron hasta 180 variables estructuradas que contemplaron registros de salud y de otra índole (económicos, geográficos, etc.) asociados al paciente y su entorno. Con técnicas de aprendizaje continuado se creó un algoritmo matemático capaz de ofrecer un resultado que ayudase a priorizar la gestión de las bajas. Los valores de salida del modelo predictivo fueron la predicción de los días de IT y el coeficiente “perfil alta”. La conjugación de estos dos valores en el control y el seguimiento de las bajas permitió adecuar las acciones al momento más oportuno. La mejora de los resultados de las variables del estudio, ya sea las variables específicas de gestión de la CC o las variables generales de gestión, evidenció que para este supuesto fuese adecuada la implantación de un modelo predictivo de aprendizaje continuo. En este sentido, se demostró el beneficio en la selección de las bajas a gestionar y adecuar las acciones al momento más oportuno, con la mejora de los indicadores de duración media de las altas, el número global de propuestas de alta y el porcentaje de éxito de las altas. Además, la tendencia descendente de la prevalencia mensual durante el segundo trimestre de 2022 de los CA participantes en la prueba piloto culminó en una mejora en los resultados económicos, al reducir el importe de la prestación económica. Añadir que este modelo se entrenó para mejorar su rendimiento a medida que se fue mejorando la calidad de los registros en las historias clínicas y seguirá mejorando con el paso del tiempo.

Este estudio no está exento de limitaciones. En primer lugar, el modelo ha sido evaluado en una prueba piloto de corta duración y por tanto se ha de ampliar este periodo de análisis. Por otra parte, el muestreo por conveniencia de los CA puede suponer un sesgo, puesto que se podían haber obtenido resultados diferentes con otros centros y por tanto no se conoce hasta qué punto los resultados obtenidos son representativos de la población a escala nacional.

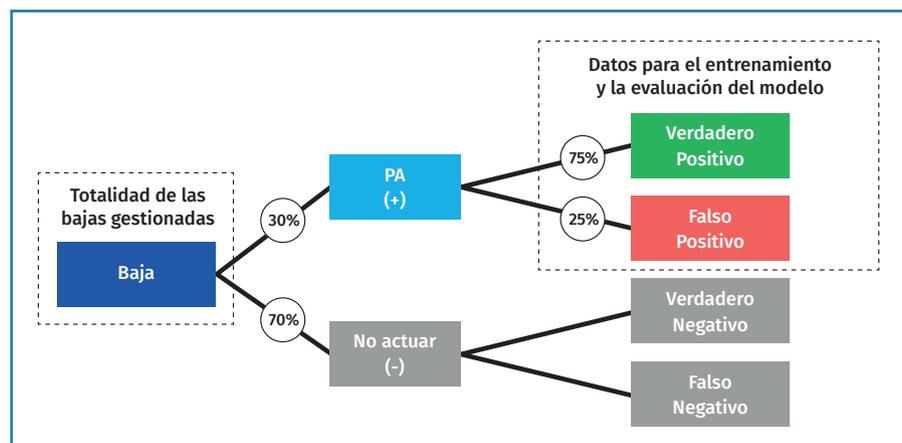


Figura 3. Modelo predictivo “perfil alta”. Fuente: datos internos mutua.

Por todo ello, se debería ampliar el periodo de análisis y el universo de centros para confirmar que la mejora de los indicadores se mantiene a largo plazo. Otra limitación del estudio fue que el entrenamiento del valor “perfil alta” lo fue siempre de los registros en los episodios de baja con propuesta de alta ya realizada (Figura 3) y, además, por propia idiosincrasia del proceso de gestión siempre existirán procesos que por primera vez se enfrenten a una valoración por parte de la mutua.

Por último, cabe señalar que no se pudieron incorporar en el desarrollo del modelo todos aquellos datos registrados en la historia clínica que no estuviesen estructurados, por ejemplo, el texto libre del curso clínico, el resultado de las pruebas complementarias, anamnesis o diagnósticos secundarios, aspectos a añadir en el futuro modelo predictivo y su implementación.

A pesar de estas limitaciones, la mejora observada en los indicadores de gestión de CC en los CA durante la prueba piloto, tanto en la comparación de casos piloto *versus* centros piloto, así como la comparativa con los datos globales de la mutua, sugiere que priorizar la gestión asistencial de los procesos de baja por CC mediante estos valores predictivos puede ayudar a concentrar los recursos asistenciales en un menor número de procesos de baja. Es la llamada “gestión de volúmenes”. Además, incorporar en el modelo de gestión de la CC los valores predictivos “días de duración de la IT” y “perfil alta” permite anticipar cuál es el momento más adecuado para realizar determinadas acciones en estos procesos asistenciales y en definitiva mejorar la eficacia y la eficiencia, con todo el impacto económico que ello comporta.

### Conclusiones

El uso de los valores predictivos “días de duración de IT” junto con el coeficiente “perfil alta” ha permitido focalizar la gestión en un menor número de procesos de baja y conseguir una mejora en los indicadores de gestión.

El modelo de analítica predictiva ha mejorado los indicadores de gestión específicos de CC (mejora de la duración media de las altas, porcentaje de altas con PA, porcentaje de éxito de estas) y los indicadores de gestión generales (prevalencia).

Aunque el valor del indicador de la prevalencia se incrementó levemente en la zona piloto, este incremento fue menor que el observado en el resto de la mutua.

La aplicación de un modelo de analítica predictiva en pacientes en situación de IT por CC, utilizando los valores predictivos “días de IT” y “perfil alta”, para personalizar las

acciones y llevarlas a cabo en el momento más oportuno, puede mejorar la eficacia y eficiencia en la gestión, por concentrar los recursos en un menor número de procesos a gestionar y reduciendo en un potencial impacto económico.

Si bien los resultados del análisis indican una mejora de los indicadores, se debería ampliar el periodo y el ámbito geográfico del análisis para confirmar este extremo.

### Responsabilidades éticas

**Protección de personas y animales.** Los autores declaran que para esta investigación no se han realizado experimentos en seres humanos ni en animales.

**Confidencialidad de los datos.** Los autores declaran que han seguido los protocolos de su centro de trabajo sobre la publicación de datos de pacientes.

**Derecho a la privacidad y consentimiento informado.** Los autores declaran que en este artículo no aparecen datos de pacientes.

**Financiación.** Los autores declaran que este trabajo no ha sido financiado.

**Conflicto de interés.** Los autores declaran no tener ningún conflicto de intereses.

### Bibliografía

1. Informe absentismo laboral. Segundo trimestre 2022. Randstad Research; 2022. Disponible en: <https://www.randstadresearch.es/informe-absentismo-laboral-segundo-trimestre-2022/>.
2. Ministerio de Inclusión Seguridad Social y Migraciones. Listado de estadística oficial de la Seguridad Social: Acumulado al mes de diciembre de 2022 de incapacidad temporal, agregado del sistema. Subdirección General de seguimiento Económico de la Seguridad Social; 2022. Disponible en: <https://fondoscience.s3.eu-west-1.amazonaws.com/fs-retla-docs/retla.06111.fs2303001-22-SIS-CC-DM-PRE.xlsx>
3. Ministerio de Inclusión Seguridad Social y Migraciones. Listado de estadística oficial de la Seguridad Social: Acumulado al mes de diciembre de 2022 de incapacidad temporal, agregado de las mutuas colaboradoras. Subdirección General de seguimiento Económico de la Seguridad Social; 2022. Disponible en: <https://fondoscience.s3.eu-west-1.amazonaws.com/fs-retla-docs/retla.06111.fs2303001-22-MUT-CC-DM-PRE.xlsx>
4. Martínez J. Las 7 Fases del Proceso de Machine Learning. IArtificial.net; 2020.
5. Clavería P. Big Data, conceptos y alcance de las tecnologías disponibles. Rev I+S. Sociedad Española de Informática de la Salud. 2016;119.