

Autor: Julianna Ribera Caterina | Amalfi Analytics

Contacto: Julianna Ribera Caterina | *Directora Médica*
julianna@amalfianalytics.com

Agradecimientos: Hospital Universitario de Cabueñes (Gijón)
Fundació Privada Hospital Asil de Granollers
Fundació Salut Empordà (Figueres)

INTRODUCCIÓN

Hay un antes y un después de la utilización de los grupos relacionados de diagnóstico (GRD) en la gestión hospitalaria. Con más de 20 años, se han ajustado, refinado, y utilizado ampliamente, aunque manteniendo siempre algunas consideraciones respecto a su aplicación para la mejora de los procesos de atención.



Presentamos una **herramienta basada en algoritmos Machine Learning**, que complementa el análisis y la gestión de casos con los agrupadores clásicos, permitiendo enfocar acciones de mejora según el perfil de paciente.

Facilita a los responsables de Servicios asistenciales el conocimiento de la variabilidad del case-mix y permite identificar los factores prevalentes en los grupos de más riesgo frente a las desviaciones en los resultados de indicadores de calidad.



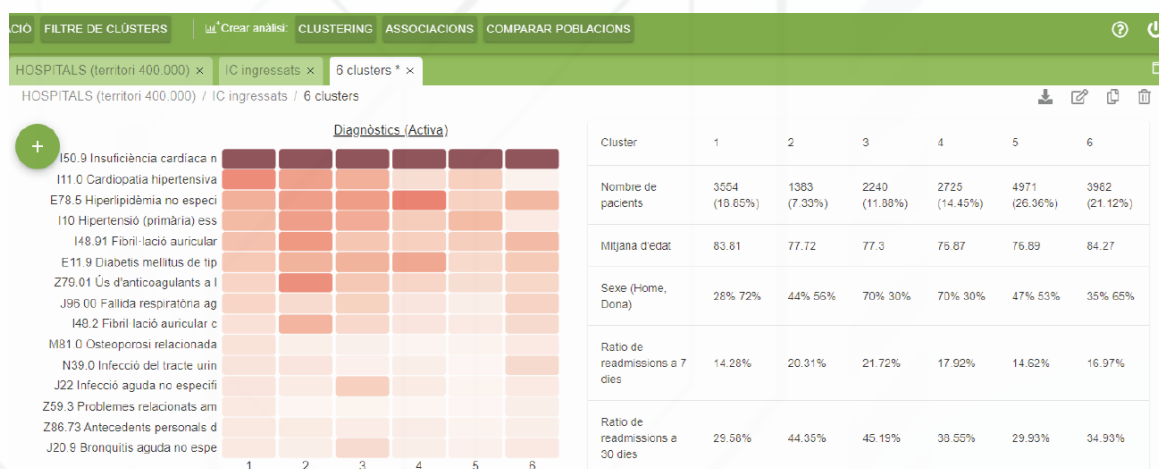
OBJETIVOS

- Dotar a los servicios de Admisión y Documentación de una potente herramienta de análisis para **facilitar la gestión de procesos** a los servicios asistenciales.
- **Enfocar las acciones de mejora** en los perfiles con más riesgo, por parte de los servicios médicos.
- Introducir la inteligencia artificial en los servicios de soporte para **potenciar la productividad**.



METODOLOGÍA

Mediante el histórico del conjunto mínimo básico de datos (cmbd-ah) seudonimizado, y realizando la carga periódica mensual, se dispone de la base de casos necesaria para el análisis de patrones.



Un algoritmo de *clustering* divide los pacientes en conjuntos de diagnóstico parecidos. Este algoritmo, a diferencia de algoritmos de *clustering* tradicionales, está diseñado para soportar, con robustez y eficiencia, la gran cantidad de diagnósticos posibles definidos por los estándares ICD9/ICD10 y permite agrupar conjuntos de pacientes, desde unas pocas decenas hasta centenares de miles.

Asimismo, clasifica por probabilidades y no solamente por prevalencia, con lo cual permite una visión mejor de los **patrones de comorbilidades** de un proceso y los patrones de tratamiento asociados a cada grupo.



RESULTADOS Y CONCLUSIONES

Se ha realizado una prueba funcional para evaluar su aplicación en real. Los hospitales participantes son de diferentes niveles, desde el Hospital Universitario de referencia, hasta el comarcal.

La flexibilidad de la herramienta ha permitido desde la identificación de patrones dentro de un Servicio de Medicina Interna para **mejorar los protocolos de abordaje multidisciplinar** de pacientes complejos, analizar **intervenciones concretas para disminuir la mortalidad** en fracturas de fémur, **identificar los factores diferenciales en estancia media** desviada, hasta la planificación de necesidades en **atención domiciliaria**.

Poder revisar y actuar sobre un 10-20% de los casos, que son los patrones que generan desviaciones en mortalidad, readmisiones, estancia, etc., y hacerlo de forma autónoma y con un tiempo de análisis un 80% menor, comparado con otros sistemas, permite un alcance en el soporte a la mejora importante para mantener la calidad asistencial en tiempos difíciles como los que se avecinan en los próximos años y se instalarán para el futuro previsible.

La inteligencia artificial y en concreto el aprendizaje de máquina, nos ayuda a conocer y tratar mejor a nuestros pacientes.

