

ALGOPROMIA: Implementación de Machine Learning para la predicción de resultados de PROs en la Estrategia 'No Hacer' para una Atención Sanitaria Basada en Valor.

CONTEXTO:

Según la Comisión Europea [1], el futuro de los sistemas de salud se orientará hacia el paciente, promoviendo hábitos saludables y una conectividad digital integral entre pacientes, profesionales y organizaciones sanitarias. La Medicina Basada en la Evidencia (MBE), un concepto introducido por Gordon Guyatt [2], subraya la necesidad de aplicar la evidencia científica más sólida en la práctica clínica diaria, requiriendo una incorporación meticulosa, juiciosa y transparente de dichas evidencias en decisiones relacionadas con el cuidado de la salud. En el contexto sanitario contemporáneo, la Atención Sanitaria Basada en Valor se ha consolidado como el paradigma emergente que busca redefinir cómo se brinda y se evalúa el mejor cuidado médico. Michael Porter, uno de los principales impulsores de esta filosofía, ha subrayado la necesidad de centrarse en los resultados obtenidos en relación con los costos [3], resultando las herramientas de **Patient-Reported Outcomes (PRO)** y **Patient-Reported Experience (PRE)** esenciales para la evaluación no solo de la perspectiva del paciente, sino que también como métricas adecuadas para comparar y evaluar acciones y estrategias de gestión sanitarias. En este marco, las estrategias "No Hacer" (NO HACER) se alinean con el objetivo de eliminar intervenciones innecesarias, optimizando los recursos y garantizando que cada acción médica aporte valor real al paciente [4-5].

La **Comunidad NAVETA** está impulsada por la Asociación de Farmacéuticos de Departamentos de Pacientes Externos de las Islas Baleares (FARUPEIB) en colaboración con **BiblioPRO** (<http://www.bibliopro.org>, Barcelona, España), una biblioteca virtual especializada en cuestionarios de Resultados Reportados por el Paciente (PRO) en español. **NAVETA** (www.navetahealth.com) tiene como misión el fomentar una medicina basada en valor promoviendo el uso de las herramientas PRO/PRE en conjunto con aplicaciones de Telemedicina para optimizar la atención al paciente. La infraestructura tecnológica que respalda las actividades de NAVETA es proporcionada por **Premium**, una plataforma de software especializada en proyectos de telemedicina. Recientemente **Comunidad NAVETA** ha sido galardonada por diferentes asociaciones españolas como un proyecto innovador destacado, siendo una de las iniciativas de atención sanitaria basada en el valor más extendidas en España, y ha sido ampliamente implementada en más de 60 hospitales e instituciones en diferentes regiones españolas (SEFH, 2021). La comunidad NAVETA reúne a diversos profesionales, incluyendo gestores hospitalarios, médicos, farmacéuticos hospitalarios, psicólogos, biólogos y tecnólogos de eHealth, que forman el **Comité Científico de NAVETA**.

Como se ha dicho, los cuestionarios PRO (Patient-Reported Outcomes), se han convertido en instrumentos esenciales para capturar la perspectiva del paciente y evaluar el impacto real de las intervenciones en su calidad de vida, actividad de la enfermedad, satisfacción con la asistencia sanitaria [3]. Por otra parte, la gran cantidad de datos generado de por la telemedicina ha propiciado la llegada de nuevas técnicas

de análisis de datos como las técnicas de Machine Learning (ML). **Por lo que integrar la predicción de las puntuaciones de cuestionarios PRO/PRE mediante técnicas de Machine Learning podría traer varias ventajas:** 1) Personalización avanzada de los planes de tratamiento basada en las expectativas y experiencias del paciente, 2) Optimización de recursos al prever necesidades y ajustar intervenciones, 3) Mejora en la toma de decisiones clínicas a través de análisis predictivos precisos, y 4) Fortalecimiento del compromiso y satisfacción del paciente al sentirse activamente involucrado y escuchado en su proceso de atención [6]. En este contexto nace el proyecto **ALGOPROMIA**.

Objetivo:

El principal propósito de **ALGOPROMIA** es desarrollar y validar una metodología basada en técnicas avanzadas de Machine Learning para predecir con precisión las puntuaciones de cuestionarios PRO/PRE. Estas puntuaciones, que reflejan directamente las percepciones y experiencias de los pacientes con respecto a su salud, tratamiento y cuidado médico, son cruciales para evaluar la calidad y eficacia de las intervenciones médicas desde una perspectiva centrada en el paciente.

Necesidad que Cubre:

En el panorama actual de la atención sanitaria, hay un creciente reconocimiento de la importancia de adoptar un enfoque basado en valor, que busca equilibrar costos, resultados y experiencias del paciente. La estrategia "NO HACER" emerge como una de las piedras angulares de este enfoque, alentando la evitación de intervenciones médicas innecesarias que no aportan valor real al paciente y que pueden llevar a gastos ineficientes y resultados subóptimos. **ALGOPROMIA** quiere contribuir a la estrategia NO HACER **proporcionando herramientas analíticas que pueden predecir y, por lo tanto, guiar de manera proactiva las decisiones clínicas basándose en las autopercepciones reportadas por los pacientes.**

BREVE DESCRIPCIÓN DE LA PUESTA EN MARCHA Y LA EXPERIENCIA

El proyecto **ALGOPROMIA**, es un **proyecto pionero en la predicción de puntuaciones de cuestionarios PRO/PRE mediante técnicas de Machine Learning**, impulsado por la **comunidad NAVETA**. Tras la reunión del Comité Científico de NAVETA, celebrada en Palma en junio de 2023, se estableció como uno de los **objetivos primordiales** en la hoja de ruta de NAVETA para los próximos años, el **impulso y la implementación de modelos predictivos sustentados en técnicas de aprendizaje automático**. Esta decisión se fundamenta en la rica información acumulada dentro del ámbito de la telemedicina. Dichos modelos contribuirán a desvelar relaciones y tendencias subyacentes en los conjuntos de datos de pacientes, optimizando así la toma de decisiones clínicas y reforzando la atención personalizada preventiva en el dominio de la telemedicina. En este escenario surge **ALGOPROMIA**, cuyo objetivo específico es desarrollar un modelo predictivo apoyado en algoritmos de Aprendizaje Automático para prever valores PRO/PRE utilizando las fortalezas actuales de la Comunidad NAVETA: **Infraestructura tecnológica, Comité científico, datos de más de 3.500 pacientes crónicos en seguimiento y las técnicas de Machine Learning** (Fig.1.).

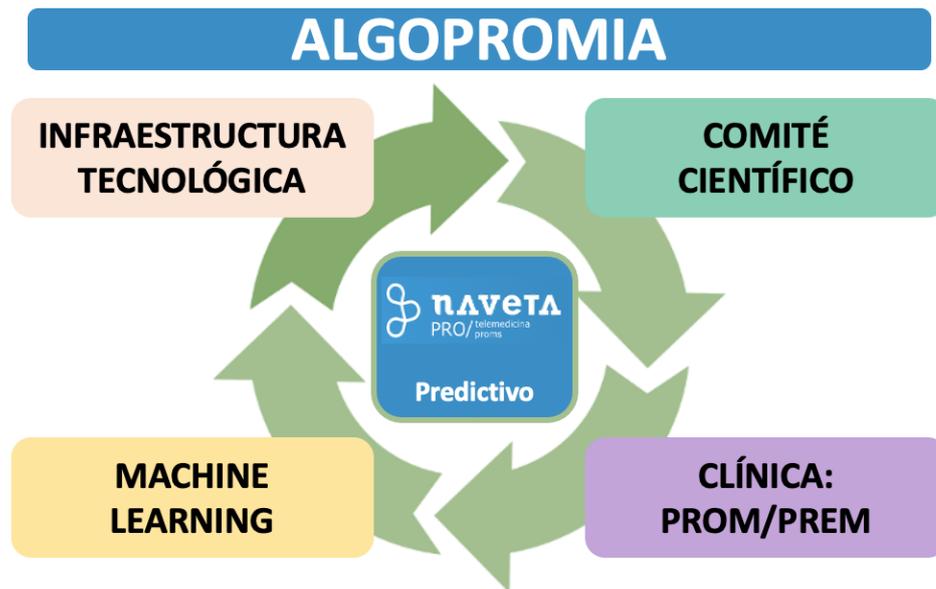


Figura 1: La infografía ilustra el robusto ecosistema de NAVETA, destacando sus fortalezas inherentes. Con una infraestructura tecnológica bien establecida como base, un gran equipo multidisciplinar de expertos que conforman el Comité Científico, y una amplia colección de datos acumulados durante tres años, en más de 3.500 pacientes crónicos. Este conjunto de recursos se ve enriquecido aún más con la integración del Machine Learning, marcando una evolución en la capacidad de NAVETA para aportar valor en el ámbito de la salud personalizada, mediante el análisis predictivo de resultados de PROs.

Actualmente la cohorte NAVETA cuenta con más de 3,500 pacientes distribuidos por diversas condiciones crónicas incluidas: artritis reumatoide, VIH, enfermedad de Crohn, psoriasis, cáncer de próstata, cáncer de mama, entre otras. Desde la plataforma de telemedicina, NAVETA se ha enviado más de 53,000 cuestionarios PRO/PRE, con una elevada tasa de respuesta. Además de los cuestionarios PRO/PRE en la plataforma de telemedicina de NAVETA se recogen una serie de variables de carácter sociodemográfico tales como sexo, edad, peso, altura, estado civil o actividad física entre otras.

Fases del proyecto:

1. **Desarrollo del prototipo:**

Durante esta fase, se conceptualiza y diseña una versión preliminar del modelo basado en especificaciones técnicas y necesidades clínicas identificadas. Se emplean algoritmos preliminares, conjuntos de datos de entrenamiento y se establece una infraestructura básica para simular su funcionalidad en un entorno controlado. Además, mediante técnicas de reducción de variables, deberán seleccionar aquellas más importantes de todo el conjunto de datos existente.

2. **Publicación en revistas de impacto los modelos de ML:**

Una vez que el modelo ha sido diseñado y probado en un entorno teórico, se procederá a documentar los resultados, metodologías y hallazgos en un manuscrito científico. Este documento se enviará a revistas científicas de alto

impacto especializadas en aprendizaje automático y ciencias de la salud. La aceptación en estas revistas respalda la solidez y relevancia del modelo desarrollado.

3. Implementación del prototipo y Validación clínica:

Posteriormente, el prototipo se instalará en forma de programa informático (app, app web, etc.) en un entorno real para realizar pruebas más extensas y la validación clínica. Es esencial verificar la precisión, confiabilidad y aplicabilidad del modelo en un contexto clínico real. Durante la validación clínica, se recolectan y analizan datos reales de pacientes para comparar las predicciones del modelo con los resultados clínicos reales. Las discrepancias se registran y se ajustará el modelo en consecuencia para mejorar su precisión y fiabilidad. En esta fase será esencial la colaboración de los profesionales clínicos y asistenciales que forman parte Naveta, si bien es cierto, que se podrá invitar a otros miembros de la comunidad asistencial NAVETA.

4. Implementación del módulo NAVETA-Predictivo:

Una vez que el modelo ha sido validado clínicamente, se integrará como un módulo dentro de la plataforma NAVETA. Este módulo predictivo se adaptará para garantizar una interacción fluida con otras características de la plataforma y se someterá a pruebas rigurosas para garantizar su eficiencia y eficacia en el entorno de NAVETA.

Resultados preliminares:

Actualmente desde el comité científico de NAVETA ya se está impulsado este proyecto, si bien es cierto que **se encuentra en una fase muy temprana**, actualmente podemos mostrar algunos datos preliminares. Estos datos serán presentados al congreso europeo **28th Congress of the EAHP** (<https://www.eahp.eu/congresses>) de forma que esperamos recibir *feedback* de otros colegas, mejorando el prototipo inicial.

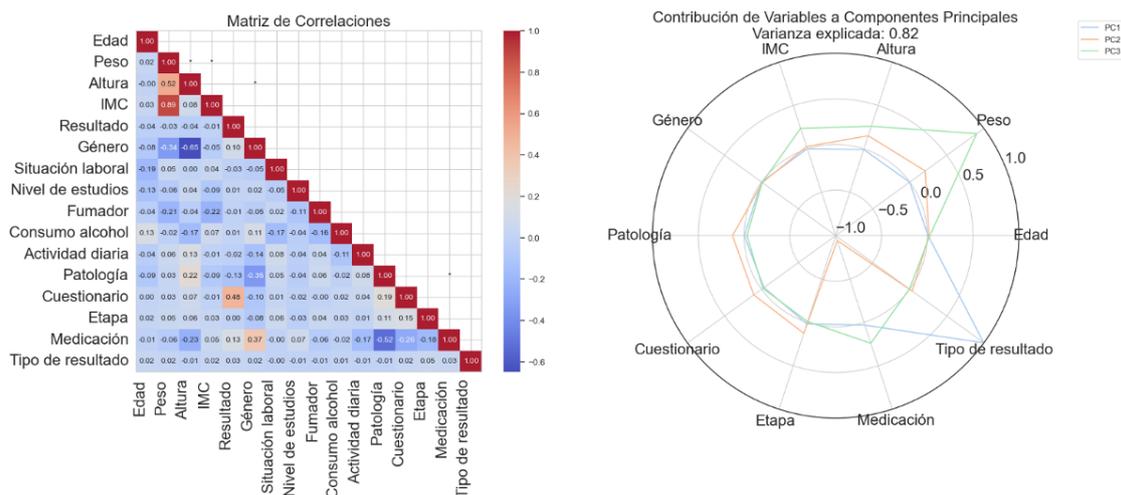


Figura 2: Matriz de correlación de las variables de interés. Se muestran las relaciones lineales entre cada par de variables (Izquierda). A la derecha, el gráfico radar que representa los pesos de las principales componentes obtenidas tras un Análisis de

Componentes Principales (PCA), desde las que se selecciona las variables más importantes, que fueron incluidas en el subsiguiente modelo de Machine Learning. Después de elegir las variables más relevantes (Fig. 2) se evaluaron diversos modelos, y determinamos que el modelo Random Forest demostró ser altamente predictivo, con un ¹R-cuadrado de 0,93, captando con eficacia la variabilidad de las medidas PRO/PRE (Fig.3)

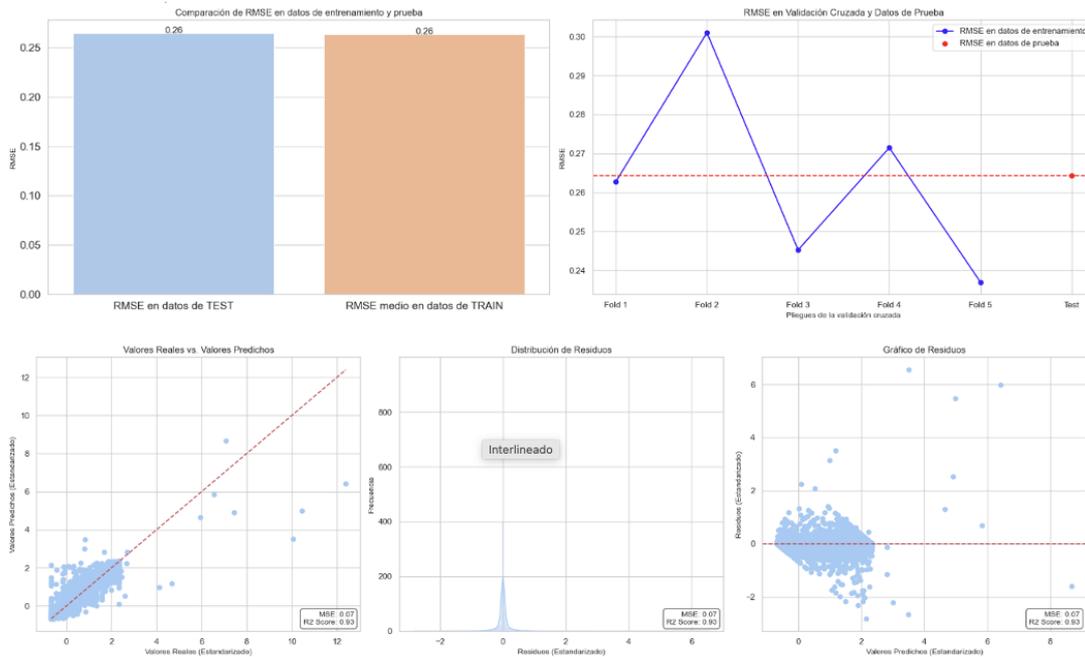


Figura 3: En la parte superior, se presentan las métricas del modelo: ²RMSE en datos de prueba es 0.2934, mientras que en validación cruzada para datos de entrenamiento varía entre 0.2865 y 0.3265 con un RMSE medio de 0.3013. La diferencia entre el RMSE en datos de entrenamiento y prueba es -0.0079 indicando que el modelo se comporta mejor en el grupo de validación y que no hay efecto de sobre-entrenamiento (overfitting). En la parte inferior, se muestran tres gráficos: *Gráfico de dispersión de valores reales vs. predichos* - Los residuos son predominantemente cercanos a cero, confirmando que las predicciones son similares a los valores reales. *Gráfico de Distribución de Residuos* - Los residuos siguen una distribución normal con una media cercana a cero, lo que sugiere un buen ajuste del modelo. *Gráfico de residuos* - Las predicciones son coherentes y cercanas a los valores reales, destacando la precisión del modelo.

A continuación, definimos ad hoc una métrica que captase la calidad de la predicción de nuestro prototipo: establecimos el **error máximo permitido** dentro del 25 % del rango puntuación de un PRO/PRE (por ejemplo, 0-100 serían 25 puntos). Las

¹ El R-cuadrado o coeficiente de determinación, es una estadística que proporciona una medida de cuán bien las observaciones de una muestra se ajustan al modelo estadístico lineal. Se interpreta como la proporción de la variabilidad total de la respuesta explicada por el modelo.

² El RMSE, o Root Mean Square Error (en español, Raíz del Error Cuadrático Medio), es una medida ampliamente utilizada para cuantificar la precisión de un modelo predictivo. Específicamente, el RMSE representa la raíz cuadrada de la diferencia entre los valores predichos y los valores observados (o reales).

predicciones se calificaron como 'excelentes' si el ³MSE estaba dentro del 25% de esta referencia, 'buenas' dentro del 50%, 'moderadas' dentro del 75%, y 'fuera de rango' si superaban estos valores. **Este método ofrece una evaluación ponderada de la precisión de la predicción para las puntuaciones PRO en base a su rango total.** A lo largo del desarrollo de nuestro prototipo, varias lecciones valiosas emergieron. Principalmente, detectamos que ciertas variables inicialmente consideradas no proporcionaban la robustez esperada al modelo, lo cual llevó a una revisión y optimización de la selección de características (Fig.2). Esta adaptación resultó en una mejora significativa en la precisión del algoritmo. Además, la validación cruzada mostró la necesidad de reajustar algunos parámetros para evitar el sobreajuste (Fig.3).

Nuestro prototipo inicial **clasificó el 40% de los cuestionarios como 'excelente' o 'bueno'**, incluyendo el WRFQ (Work Role Functioning Questionnaire), HIV SI (HIV Symptom Index), MOS30 HIV (Medical Outcomes Study-short form 30 items) and DLQI (Dermatology Life Quality Index). Sugiriendo que las puntuaciones de estos cuestionarios son susceptibles de ser predichos con una gran calidad. **Estos resultados, aunque prometedores**, son preliminares y subrayan la necesidad de **una investigación más profunda sobre el comportamiento del modelo**. Es esencial considerar tanto el estudio teórico del modelo como la adquisición de más datos para garantizar una comprensión más holística. En particular, **queremos enfatizar la importancia de realizar más pruebas y expandir nuestra base de datos con un mayor número de pacientes**. La consolidación de estos hallazgos requerirá un análisis más detallado y riguroso en etapas futuras de investigación. De forma concreta se prevén dos acciones esenciales.

1. El **incremento de la cohorte NAVETA** es una de nuestras prioridades actuales. Para conseguir un mayor reclutamiento de pacientes, estamos colaborando estrechamente con diversos profesionales clínicos. Estos expertos, que forman parte del Comité Científico de NAVETA o bien son invitados a unirse, jugarán un papel crucial en liderar esta fase de expansión de la cohorte NAVETA.
2. Paralelamente, es imperativo **seguir investigando y perfeccionando el diseño del algoritmo** más óptimo para nuestras necesidades. Buscamos un modelo que maximice la captura de la varianza en los datos, lo que se traduce en predicciones de mayor calidad por cuestionario.
3. Colaborar en iniciativas para compartir datos en Open acces, para compartir datos y conocimiento.

Esperamos que estas acciones, además de mejorar la calidad de las predicciones existentes, nos abrirá la puerta para **incorporar nuevos cuestionarios al sistema de predicción**, centrados en patologías esenciales dentro del ecosistema NAVETA, como la psoriasis o el VIH, pero también otras como migraña o esclerosis múltiple.

³ El MSE, o Mean Squared Error (Error Cuadrático Medio en español), es una métrica utilizada para medir la diferencia entre los valores predichos por un modelo y los valores reales. Específicamente, se calcula tomando la diferencia entre cada valor predicho y el valor real correspondiente, elevando cada diferencia al cuadrado, sumando todas las diferencias cuadradas y luego dividiendo por el número de observaciones. Un MSE más bajo indica que las predicciones del modelo son más precisas.

Con estos avances, **para los que se solicita el apoyo de la iniciativa CANOHA**, esperamos consolidar aún más nuestra posición como líderes en el ámbito de la telemedicina basada en valor y en el uso de Machine Learning para el análisis predictivo de puntuaciones PRO/PRE.

IMPACTO: RELEVANCIA EN EL CONTEXTO ACTUAL

Más allá de las ventajas operativas y económicas de propio uso de los cuestionarios PRO/PRE, **proyectos como ALGOPROMIA tienen un potencial impacto en la práctica clínica**. No solo refinando el proceso de toma de decisiones médicas, sino que también se enfatiza y prioriza la voz del paciente. **Estamos convencidos de que esta combinación de técnicas de Machine Learning y métricas como los cuestionarios PRO/PRE impulsará una atención más personalizada, informada y alineada con los valores y expectativas del paciente, sentando las bases para un sistema de salud más humano y eficiente**. De forma concreta el impacto que se espera obtener con ALGOPROMIA se puede dividir en tres aspectos

Gestión Asistencial:

La implementación de modelos predictivos permite anticipar y garantizar una alta calidad en la prestación de servicios médicos. A través de la identificación temprana, es posible **prever riesgos**, ofreciendo un **diferenciador competitivo en el mercado**. Esto, a su vez, potencia la retención tanto de profesionales de la salud como de pacientes, creando un ambiente de confianza y **excelencia**. Todo ello se debe traducir en una utilización más eficiente de los recursos, determinando acciones de RIGHT CARE, y reorientando a la distribución de recursos a las intervenciones detectadas como más eficientes y más bien valoradas por los pacientes y profesionales

Clínica:

La utilización de tecnologías avanzadas promueve una mejora significativa en la calidad de vida del paciente. Los modelos predictivos proporcionan una **perspectiva anticipada sobre los resultados específicos de un paciente**, permitiendo un seguimiento más certero de las puntuaciones PRO/PRE y, por ende, una mejor adaptación de los tratamientos y acciones sanitaria en general. Esta precisión se traduce en una **mayor adherencia** al tratamiento por parte de los pacientes, al sentir que sus necesidades son entendidas y atendidas de forma personalizada.

Industria:

En el ámbito industrial, los modelos predictivos **potencian la realización de estudios cost-utility**, aportando una visión más clara sobre la rentabilidad y eficiencia de los tratamientos y servicios ofrecidos de forma virtualizada. Además, facilitan la implementación de **proyectos piloto**, probando y adaptando innovaciones en entornos controlados antes de su lanzamiento a gran escala.

Medio ambiental:

El uso de modelos predictivos nos permitirá una utilización más eficiente de los recursos que puedan implicar menos desplazamientos en vehículo de los pacientes a los centros

sanitarios, lo cual puede ayudar a reducir la huella de carbono, que va alineado con los Objetivos de Desarrollo sostenible 2030, Salud y bienestar, Ciudades y comunidades sostenibles, Producción y consumo responsables, Acción por el Clima.

CAMBIOS Y MEJORAS IMPORTANTES

Con la incorporación de técnicas de Machine Learning en el proyecto NAVETA, se pretenden promover varios cambios y mejoras esenciales:

1. **Optimización del análisis de datos:** La implementación de algoritmos de aprendizaje automático permitirá un análisis más profundo y rápido de los datos, lo que facilitará la identificación de tendencias y patrones complejos que antes podrían haber sido pasados por alto.
2. **Personalización de la atención:** Gracias al Machine Learning, será posible prever con mayor precisión las necesidades específicas de los pacientes, lo que permitirá una atención más individualizada y un tratamiento más ajustado a sus particularidades.
3. **Mejora en la eficiencia:** La capacidad de predecir con precisión las puntuaciones PRO/PRE reducirá el margen de error en las decisiones clínicas y ha optimizará la asignación de recursos, promoviendo la reducción de gastos innecesarios, y potenciando la eficiencia y la mejor asignación de recursos.
4. **Actualización constante:** Con la adición del Machine Learning, el sistema se beneficia de la capacidad inherente de estos algoritmos para "aprender" constantemente, adaptándose y mejorando con cada nuevo conjunto de datos ingresado.
5. **Mejora en la formación del equipo:** La integración del Machine Learning ha requerido una capacitación y actualización constante del equipo multidisciplinario, elevando el nivel de *expertise* en el manejo de técnicas avanzadas de análisis de datos.

BIBLIOGRAFIA:

1. European Commission. Defining Value in Value-Based Healthcare. [Internet]. Disponible en: https://ec.europa.eu/health/sites/default/files/expert_panel/docs/024_defining-value-vbhc_en.pdf
2. Medicine Clinical Practice. AMA Press, EE.UU. 2002
3. Porter ME. What is value in health care? N Engl J Med. 2010 Dec 23;363(26):2477-81. doi: 10.1056/NEJMp1011024. Epub 2010 Dec 8. PMID: 21142528.
4. Gentry S, Badrinath P. Defining Health in the Era of Value-based Care: Lessons from England of Relevance to Other Health Systems. Cureus. 2017 Mar 6;9(3):e1079. doi: 10.7759/cureus.1079. PMID: 28405529; PMCID: PMC5383371.
5. Allen-Duck A, Robinson JC, Stewart MW. Healthcare Quality: A Concept Analysis. Nurs Forum. 2017 Oct;52(4):377-386. doi: 10.1111/nuf.12207. Epub 2017 Apr 13. PMID: 28407249; PMCID: PMC5640472.
6. Cruz Rivera S, Liu X, Hughes SE, Dunster H, Manna E, Denniston AK, Calvert MJ. Embedding patient-reported outcomes at the heart of artificial intelligence health-care technologies. Lancet Digit Health. 2023 Mar;5(3):e168-e173. doi: 10.1016/S2589-7500(22)00252-7. PMID: 36828609.