COMILLAS
UNIVERSIDAD PONTIFICIA
ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

Impacto del uso del móvil en biomarcadores de bienestar: un estudio N=1 con wearable y aumentación de datos

Autor: Vicente Sánchez Gil

Director: Gregorio López López

Codirectores: Mario Castro Ponce, Lucía Halty Barrutieta

Madrid, junio de 2026

Declaración de originalidad

Declaro bajo mi responsabilidad que el Proyecto presentado con el título **Impacto del uso del móvil en biomarcadores de bienestar: un estudio N=1 con wearable y aumentación de datos** en la ETS de Ingeniería – ICAI de la Universidad Pontificia Comillas en el curso académico 2025-2026 es de mi autoría y no ha sido presentado con anterioridad a otros efectos. El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido tomada de otros documentos está debidamente referenciada.

Uso de Inteligencia Artificial[1]

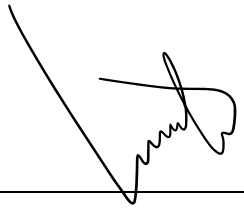
Declaro bajo mi responsabilidad que (indicar la opción correcta):

☐ No he utilizado Inteligencia Artificial en la elaboración del presente documento.

● He utilizado Inteligencia Artificial en la elaboración del presente documento y/o del Anexo B siempre en las condiciones permitidas por la Universidad Pontificia Comillas, es decir, aplicando el Nivel 2 de la Escala de Evaluación de Perkins et al. (2024): "*La IA puede utilizarse para actividades previas a la tarea, como la lluvia de ideas, la descripción y la investigación inicial. Este nivel se centra en el uso de la IA para la planificación, las síntesis y la generación de ideas, pero las evaluaciones deben hacer hincapié en la capacidad de desarrollar y refinar estas ideas de forma independiente*". En concreto, la Inteligencia Artificial ha sido empleada para:

(indicar aquí el uso concreto que se ha hecho de la Inteligencia Artificial)
En concreto, la Inteligencia Artificial se ha empleado para: la interpretación automática de las capturas de pantalla de Tiempo de Uso del iPhone, uso de Asta para la búsqueda de papers y creación de esquemas aportando todos los datos para su creación.

[1] Esta declaración se refiere al uso de la Inteligencia Artificial generativa para realizar los documentos del Proyecto (Anexo B y Memoria). No aplica a Proyectos donde, por su naturaleza, deban emplear inteligencia artificial como parte de los mismos (aplicación de técnicas de aprendizaje automático, redes neuronales, análisis de datos…)


Firmado (alumno): Vicente Sánchez
Fecha: 24/06/2026

Autorización para la entrega del Proyecto

El Director del Proyecto	El co-Director del Proyecto (si aplica)
LOPEZ LOPEZ GREGORIO IGNACIO - 75887558R Firmado digitalmente por LOPEZ LOPEZ GREGORIO IGNACIO - 75887558R Fecha: 2026.06.25 19:36:45 +02'00'	Mario Castro Firmado por: Mario Castro Fecha: 2026-06-25 20:03:42 CEST
Fdo: Gregorio López López	Fdo: Mario Castro Ponce
Fecha: 24/06/2026	Fecha: 24/06/2026

COMILLAS
UNIVERSIDAD PONTIFICIA
ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

Impacto del uso del móvil en biomarcadores de bienestar: un estudio N=1 con wearable y aumentación de datos

Autor: Vicente Sánchez Gil

Director: Gregorio López López

Codirectores: Mario Castro Ponce, Lucía Halty Barrutieta

Madrid, junio de 2026

Agradecimientos

Quiero expresar mi agradecimiento a mi director, Gregorio López López, y a mis codirectores, Mario Castro Ponce y Lucía Halty Barrutieta, por su orientación y apoyo durante todo el proyecto. De forma muy especial, agradezco al CIHS y a Lucía Halty la cesión del wearable Empática EmbracePlus, sin el cual este trabajo no habría sido posible. Gracias, por último, a mi familia y a mis amigos por su apoyo constante.

IMPACTO DEL USO DEL MÓVIL EN BIOMARCADORES DE BIENESTAR: UN ESTUDIO N=1 CON WEARABLE Y AUMENTACIÓN DE DATOS

Autor: **Sánchez Gil**, Vicente.
Director: López López, Gregorio.
Entidad Colaboradora: ICAI – Universidad Pontificia Comillas.

RESUMEN DEL PROYECTO

Este Trabajo de Fin de Grado analiza, con datos objetivos de un wearable, cómo afecta el uso del móvil al bienestar de un usuario monitorizado de forma intensiva (N=1). Combinando un índice de bienestar reproducible, técnicas de aumentación de datos y modelado estadístico, se observa que, en este sujeto, el uso del móvil no muestra indicios claros del efecto perjudicial que suele darse por hecho: su único rastro fisiológico claro es un leve aumento de la activación (EDA) que no parece trasladarse al bienestar global ni deteriorar el sueño. La aportación principal del trabajo es metodológica: un pipeline reproducible que aísla el efecto del móvil de sus factores de confusión y que podría aplicarse a estudios a mayor escala con varios participantes.

Palabras clave: wearable, Empática EmbracePlus, bienestar, uso del móvil, EDA, HRV, aumentación de datos, Moving Block Bootstrap, inferencia bayesiana, factor de confusión.

1. Introducción

El teléfono móvil es el dispositivo con el que más interactuamos a diario, y existe una preocupación creciente sobre su impacto en el bienestar: estrés, sueño y estado de ánimo. Sin embargo, la mayor parte de la evidencia se basa en cuestionarios subjetivos y rara vez se contrasta con medidas fisiológicas objetivas. Los wearables modernos permiten registrar de forma continua señales como la frecuencia cardiaca, la variabilidad cardiaca, la actividad electrodérmica o el sueño, lo que abre la puerta a estudiar esta relación con datos objetivos. Este trabajo aprovecha esa oportunidad para analizar, de forma cuantitativa y honesta, cómo se relaciona el uso del móvil con el bienestar de un usuario monitorizado de forma intensiva.

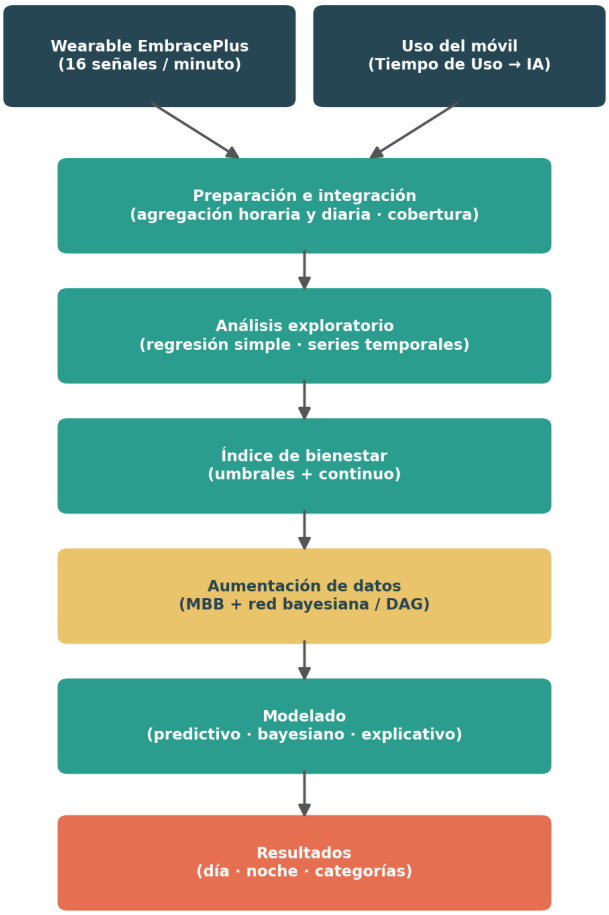
2. Definición del proyecto

El objetivo general es diseñar y validar una metodología que mida el efecto del uso del móvil sobre el bienestar a partir de un wearable, cuantificándolo de forma estadísticamente honesta. Se concreta en seis objetivos: integrar los datos del wearable y del móvil; definir un índice de bienestar objetivo; aumentar la base de datos para ganar potencia; identificar la mejor señal fisiológica; modelar el efecto del móvil controlando los factores de confusión; y reportar el resultado con su incertidumbre. La principal decisión de diseño fue trabajar con un único sujeto monitorizado intensivamente, asumiendo y tratando con rigor las limitaciones que ello implica.

3. Descripción del modelo/sistema/herramienta

El trabajo se articula como un pipeline. Los datos proceden de dos fuentes: el wearable Empática EmbracePlus (16 señales por minuto) y el uso del móvil, obtenido de las

capturas de Tiempo de Uso de iOS interpretadas mediante un modelo de inteligencia artificial con visión. Ambas fuentes se integran a resolución horaria y diaria, y se define un índice de bienestar compuesto a partir de umbrales clínicos sobre las señales. Tras un análisis exploratorio, la base de datos se amplía más de sesenta veces combinando el Moving Block Bootstrap, que multiplica el dato real preservando su estructura temporal, y una red bayesiana con un modelo causal que genera sujetos virtuales. Finalmente, se modela el efecto del móvil mediante validación bayesiana, modelos predictivos y un modelo explicativo de efectos mixtos.

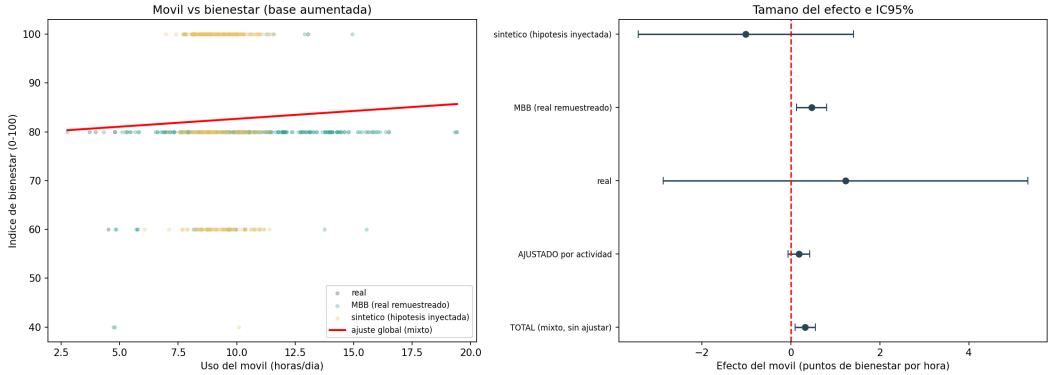


Arquitectura del pipeline del sistema, de las dos fuentes de datos a los resultados.

4. Resultados

Los resultados convergen desde varios ángulos. El único rastro fisiológico consistente del móvil es un leve aumento de la activación electrodérmica (EDA), confirmado en datos reales y sintéticos. Sin embargo, en este sujeto ese efecto no parece traducirse en un cambio del bienestar global: el modelo explicativo lo cifra en +0,32 puntos por hora de uso, pequeño y positivo, que además deja de ser significativo al controlar la actividad física. La frecuencia

cardiaca mostraba una relación negativa engañosa, artefacto del sedentarismo de los días de más móvil. De noche, ni la cantidad ni el horario del uso del móvil se asocian a un peor sueño. La validación bayesiana mostró además que el método detecta el efecto cuando existe, por lo que su ausencia en lo real es información y no falta de potencia.



Efecto del uso del móvil sobre el bienestar y su intervalo de confianza del 95 %.

5. Conclusiones

En este sujeto, el uso del móvil no muestra indicios claros del efecto perjudicial sobre el bienestar que suele darse por hecho. Su único rastro claro es un leve aumento de la activación durante el día, que no parece llegar al bienestar global ni deteriorar el sueño; en este caso, el sueño aparece como el factor más asociado al bienestar. La aportación principal es metodológica: un procedimiento reproducible y honesto que separa el efecto real del móvil de sus factores de confusión, validado mediante datos sintéticos con efecto conocido. Las principales limitaciones, un solo sujeto y pocos días, marcan las líneas futuras: ampliar a varios participantes, explotar la resolución por minuto y formalizar la cadena causal móvil → activación → bienestar.

6. Referencias

[1] Pérez, J., Castro, M., Awad, E., y López, G. (2024). Generation of probabilistic synthetic data for serious games: A case study on cyberbullying. Knowledge-Based Systems, 286, 111440.

[2] Sano, A., et al. (2018). Identifying objective physiological markers and modifiable behaviors for self-reported stress and mental health status using wearable sensors and mobile phones. Journal of Medical Internet Research, 20(6), e210.

[3] Shaffer, F., y Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. Frontiers in Public Health, 5, 258.

IMPACT OF SMARTPHONE USE ON WELLBEING BIOMARKERS: AN N=1 STUDY WITH A WEARABLE AND DATA AUGMENTATION

Author: Sánchez Gil, Vicente.
Supervisor: López López, Gregorio.
Collaborating Entity: ICAI – Universidad Pontificia Comillas.

ABSTRACT

This Bachelor's Thesis analyses, using objective data from a wearable, how smartphone use affects the wellbeing of an intensively monitored single subject (N=1). By combining a reproducible wellbeing index, data augmentation techniques and statistical modelling, it finds that, in this subject, smartphone use does not show clear signs of the harmful effect commonly assumed: its only clear physiological trace is a slight increase in arousal (EDA) that does not appear to translate into a change in overall wellbeing or to impair sleep. The main contribution of the work is methodological: a reproducible pipeline that isolates the effect of smartphone use from its confounders and that could be applied to larger studies with several participants.

Keywords: wearable, Empatica EmbracePlus, wellbeing, smartphone use, EDA, HRV, data augmentation, Moving Block Bootstrap, Bayesian inference, confounding factor.

1. Introduction

The smartphone is the device we interact with the most on a daily basis, and there is growing concern about its impact on wellbeing: stress, sleep and mood. However, most of the available evidence relies on subjective questionnaires and is rarely contrasted with objective physiological measurements. Modern wearables can continuously record signals such as heart rate, heart rate variability, electrodermal activity or sleep, opening the door to studying this relationship with objective data. This work takes that opportunity to analyse, quantitatively and honestly, how smartphone use relates to the wellbeing of an intensively monitored user.

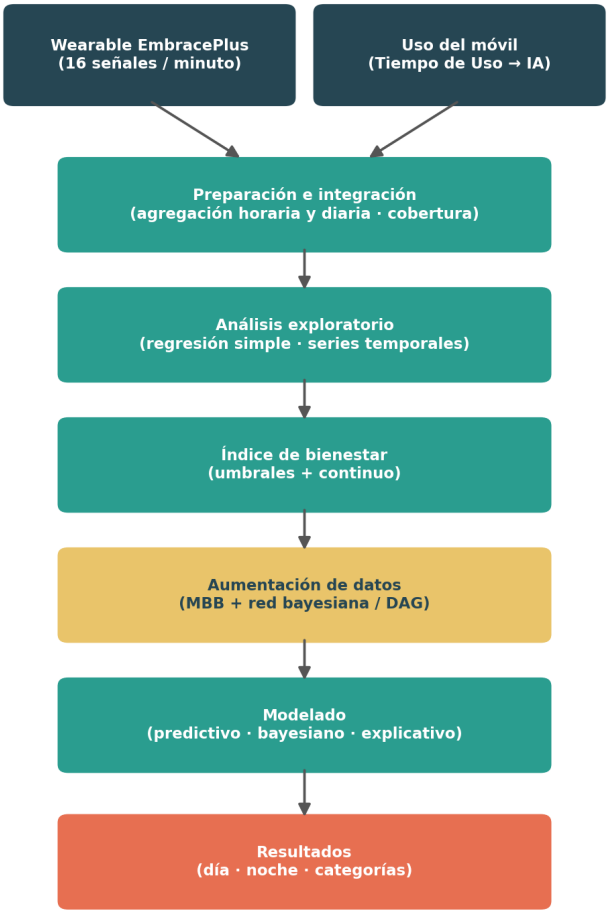
2. Project definition

The general objective is to design and validate a methodology that measures the effect of smartphone use on wellbeing from a wearable, quantifying it in a statistically honest way. It is broken down into six objectives: integrating wearable and smartphone data; defining an objective wellbeing index; augmenting the database to gain statistical power; identifying the best physiological signal; modelling the effect of the smartphone while controlling for confounding factors; and reporting the result with its uncertainty. The main design decision was to work with a single intensively monitored subject, acknowledging and rigorously handling the limitations this entails.

3. System description

The work is structured as a pipeline. Data come from two sources: the Empatica EmbracePlus wearable (16 signals per minute) and smartphone use, obtained from iOS Screen Time screenshots interpreted by a vision-capable artificial intelligence model. Both sources are integrated at hourly and daily resolution, and a composite wellbeing

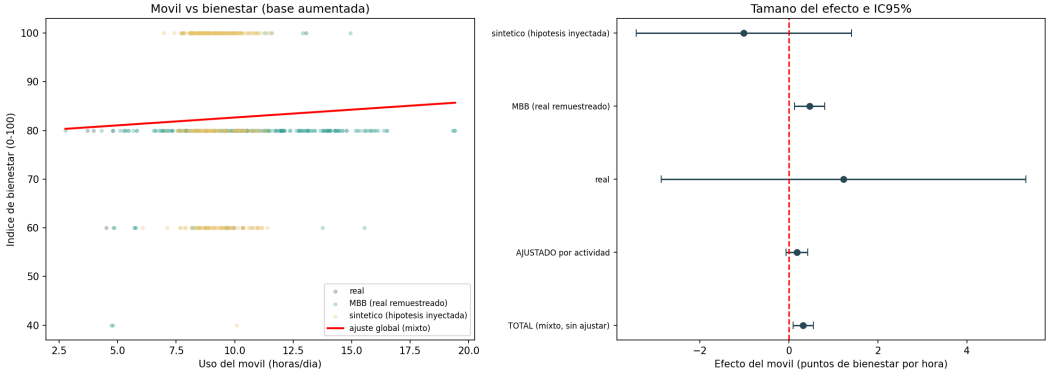
index is defined from clinical thresholds on the signals. After an exploratory analysis, the database is expanded more than sixtyfold by combining the Moving Block Bootstrap, which multiplies the real data while preserving its temporal structure, and a Bayesian network with a causal model that generates virtual subjects. Finally, the effect of the smartphone is modelled through Bayesian validation, predictive models and a final mixed-effects explanatory model.



System pipeline, from the two data sources to the results.

4. Results

The results converge from several angles. The only consistent physiological trace of the smartphone is a slight increase in electrodermal activity (EDA), confirmed in both real and synthetic data. However, in this subject, this effect does not appear to translate into a change in overall wellbeing: the explanatory model estimates it at +0.32 wellbeing points per hour of use, small and positive, which moreover becomes non-significant once physical activity is controlled for. Heart rate showed a misleading negative relationship, an artefact of the sedentary behaviour on high-usage days. At night, neither the amount nor the timing of smartphone use was associated with poorer sleep. Bayesian validation also showed that the method detects the effect when it exists, so its absence in the real data is information rather than a lack of power.



Effect of smartphone use on wellbeing and its 95% confidence interval.

5. Conclusions

Based on this study, in this subject smartphone use does not show clear signs of the harmful effect on wellbeing that is often taken for granted. Its only clear trace is a slight increase in daytime arousal, which does not appear to reach overall wellbeing or to impair sleep; in this case, sleep appears as the factor most associated with wellbeing. The main contribution is methodological: a reproducible and honest procedure that separates the real effect of the smartphone from its confounding factors, validated with synthetic data of known effect. The main limitations, a single subject and few days, set the future lines: extending to several participants, exploiting the per-minute resolution and formalising the causal chain smartphone → arousal → wellbeing.

6. References

[1] Pérez, J., Castro, M., Awad, E., & López, G. (2024). Generation of probabilistic synthetic data for serious games: A case study on cyberbullying. Knowledge-Based Systems, 286, 111440.

[2] Sano, A., et al. (2018). Identifying objective physiological markers and modifiable behaviors for self-reported stress and mental health status using wearable sensors and mobile phones. Journal of Medical Internet Research, 20(6), e210.

[3] Shaffer, F., & Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. Frontiers in Public Health, 5, 258.

Índice de la memoria

Índice de la memoria ..... ***xv***

Índice de figuras ..... ***xviii***

Índice de tablas ..... ***xx***

Capítulo 1. Introducción ***1***

1.1 Motivación del proyecto 1

1.2 Objetivos del proyecto 2

1.3 Estructura de la memoria 3

Capítulo 2. Descripción de las Tecnologías ***4***

2.1 Adquisición del uso del móvil mediante interpretación con IA 4

2.2 Evolución de la monitorización fisiológica y el wearable empleado 5

2.3 Las señales del wearable 5

2.4 Señales fisiológicas y su relación con el bienestar 6

2.5 Aprendizaje automático y estadística 7

2.6 Aumentación de bases de datos 8

2.7 Definición operativa del bienestar 8

Capítulo 3. Estado de la Cuestión ***10***

3.1 Wearables y biomarcadores de bienestar 10

3.2 Uso del móvil, sensado pasivo y bienestar digital 11

3.3 Uso nocturno del móvil y sueño 11

3.4 Estudios de un solo sujeto y digital phenotyping 12

3.5 Aumentación y generación de datos sintéticos en señales fisiológicas 12

3.6 Comparativa de trabajos previos 13

3.7 Vacíos identificados que justifican el trabajo 13

Capítulo 4. Definición del Trabajo ***15***

4.1 Justificación 15

4.2 Objetivos medibles 15

4.3 Requisitos del sistema 16

4.4 Metodología 17
4.5 Planificación y estimación económica 18

Capítulo 5. Sistema/Modelo Desarrollado 20

5.1 Arquitectura general del sistema 20
5.2 Extracción y preparación de los datos 21
5.2.1 Datos fisiológicos del wearable 21
5.2.2 Datos de uso del móvil 22
5.2.3 Integración y control de calidad 22
5.2.4 División en bloques de día y noche 23
5.3 Análisis exploratorio inicial 23
5.3.1 Regresión lineal simple 24
5.3.2 Análisis de series temporales 25
5.4 Definición del índice de bienestar 28
5.4.1 Análisis de cobertura y calidad de las señales 28
5.4.2 Índice por umbrales 29
5.4.3 Índice continuo 31
5.5 Aumentación de la base de datos 32
5.5.1 Motivación y enfoque 32
5.5.2 Capa 1, Moving Block Bootstrap 32
5.5.3 Capa 2, Red bayesiana con modelo causal 33
5.5.4 Resultado y validación 37
5.6 Análisis y modelado sobre la base aumentada 38
5.6.1 Validación bayesiana del método 38
5.6.2 Qué señales se relacionan con el bienestar 42
5.6.3 Relación multivariante entre el móvil y los biomarcadores 43
5.6.4 Selección de la mejor señal 45
5.6.5 Modelos considerados y criterio de selección 47
5.6.6 Modelos predictivos del bienestar 48
5.6.7 El modelo final: un modelo explicativo 50
5.7 Análisis del sueño (bloque noche) 52
5.7.1 Cantidad de sueño: la cadena móvil, sueño y bienestar 52
5.7.2 Calidad del sueño 53
5.8 Uso del móvil por categorías 54

Capítulo 6. Análisis de Resultados ***57***

6.1 Validez de los datos y del método 57
6.2 El efecto del móvil de día: la vía del arousal 57
6.3 El efecto del móvil de noche: el sueño 58
6.4 El tipo de uso del móvil 59
6.5 Discusión: comparación con la literatura 59
6.6 Síntesis de resultados 60

Capítulo 7. Conclusiones y Trabajos Futuros ***61***

7.1 Conclusiones 61
7.2 Aportaciones del trabajo 62
7.3 Limitaciones 62
7.4 Líneas futuras 63

Capítulo 8. Bibliografía ***65***

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS ***67***

ODS 3 – Salud y Bienestar 67
ODS 9 – Industria, Innovación e Infraestructura 67
ODS 4 – Educación de Calidad 68

ANEXO II 69

Índice de figuras

Figura 1. Cronograma del proyecto (diagrama de Gantt). 18
Figura 2. Arquitectura del pipeline: de las dos fuentes de datos a los resultados. 21
Figura 3. Regresión lineal simple entre el uso del móvil y la frecuencia cardiaca media. 24
Figura 4. Series temporales del sábado 14 de marzo (fin de semana, 281 min de móvil). 26
Figura 5. Series temporales del miércoles 18 de marzo (laborable, 821 min de móvil). 27
Figura 6. Panel diario: uso del móvil, índice de bienestar y sueño. 30
Figura 7. Grafo acíclico dirigido (DAG) del modelo causal estructural de la Capa 2. 34
Figura 8. Validación de la aumentación: distribuciones real vs MBB vs sintético, ritmo circadiano e hipótesis inyectada. 37
Figura 9. Distribuciones a posteriori del efecto del móvil en los datos sintéticos, con el valor inyectado (línea roja). 39
Figura 10. Efecto del móvil estimado para cada uno de los 25 sujetos sintéticos, con su intervalo de credibilidad. 40
Figura 11. Comparación del efecto del móvil estimado en datos sintéticos frente a datos reales. 41
Figura 12. Relación de cada señal con el índice de bienestar: correlación (izq.), importancia en RandomForest (centro) y porcentaje de días que limita el bienestar (der.). 42
Figura 13. Matriz de correlación de Spearman entre el uso del móvil y los biomarcadores (datos horarios). 43
Figura 14. Efecto del uso del móvil sobre cada biomarcador, controlando la actividad, en datos reales, MBB y sintéticos. 44
Figura 15. Asociación móvil–frecuencia cardiaca antes y después de controlar la actividad física. 45
Figura 16. Puntuación compuesta de cada biomarcador como canal para enlazar el uso del móvil con el bienestar. 46

Figura 17. Comparación de modelos por validación cruzada (izq.) y ajuste del mejor modelo, predicho frente a real (der.). 48
Figura 18. Modelo predictivo: importancia de las señales fisiológicas (izq.) y ajuste predicho frente a real (der.). 49
Figura 19. Modelo explicativo: uso del móvil frente al bienestar (izq.) y tamaño del efecto del móvil con su IC95% en distintas configuraciones (der.). 51
Figura 20. Cadena nocturna: móvil tarde-noche → sueño esa noche → bienestar del día siguiente (datos reales, n=9). 52
Figura 21. Uso del móvil (total y a horas tardías) frente a la calidad del sueño (datos reales, n=10). 54
Figura 22. Correlación entre cada categoría de uso del móvil y el bienestar y la fisiología (datos reales, n=10). 55

Índice de tablas

Tabla 1. Comparativa de trabajos previos sobre uso del móvil, wearables y bienestar. 13
Tabla 2. Cobertura efectiva de cada señal durante las horas de vigilia. 28
Tabla 3. Componentes del índice de bienestar y sus umbrales. 29
Tabla 4. Distribuciones a priori de los rasgos basales por sujeto. 35
Tabla 5. Distribuciones a priori de los coeficientes del efecto del móvil (cambio por minuto de uso)..... 36
Tabla 6. Resumen de los resultados cuantitativos principales..... 60

Capítulo 1. INTRODUCCIÓN

1.1 MOTIVACIÓN DEL PROYECTO

El teléfono móvil se ha convertido en el dispositivo con el que más horas al día interactúa una persona. Su uso intensivo ha generado una preocupación creciente, tanto social como clínica, sobre su posible impacto en el bienestar: se le atribuyen efectos sobre el estrés, la calidad del sueño, la atención y el estado de ánimo. Comprender esta relación tiene un interés evidente para la salud digital y para el diseño de hábitos tecnológicos más saludables.

Sin embargo, la mayor parte de la evidencia disponible se apoya en **cuestionarios y autoinformes**, que son subjetivos, dependen de la memoria del usuario y rara vez se contrastan con medidas fisiológicas objetivas. Esto limita la fiabilidad de las conclusiones y dificulta separar la percepción del usuario de su respuesta corporal real.

Al mismo tiempo, los dispositivos wearables han alcanzado una madurez que permite registrar de forma continua y no invasiva señales fisiológicas que antes solo se medían en laboratorio: frecuencia cardiaca, variabilidad del ritmo cardiaco, actividad electrodérmica, temperatura cutánea, respiración o patrones de sueño. Esta capacidad abre la posibilidad de estudiar la relación entre el uso del móvil y el bienestar **con datos objetivos**, cruzando el comportamiento digital del usuario con su respuesta fisiológica medida en su vida cotidiana. Este Trabajo de Fin de Grado se enmarca en esa oportunidad: aprovechar la monitorización fisiológica mediante wearables para analizar, de forma objetiva, cómo se relaciona el uso del teléfono móvil con biomarcadores de bienestar.

El alcance del fenómeno es considerable: una persona pasa varias horas al día frente a la pantalla del móvil y lo consulta decenas de veces, hasta el punto de que su uso se ha integrado en prácticamente todas las rutinas diarias. Esta omnipresencia ha situado el debate sobre sus efectos en el centro de la conversación pública, a menudo con afirmaciones tajantes, tanto alarmistas como minimizadoras, que no siempre se apoyan en evidencia sólida.

En este contexto, la salud digital busca entender la relación entre la tecnología y el bienestar con rigor científico. El reto es doble: el bienestar es difícil de medir y el uso del móvil suele evaluarse de forma subjetiva. Disponer de una persona monitorizada de forma continua con un wearable, junto con su uso real del móvil, ofrece una oportunidad poco habitual para abordar la pregunta con datos objetivos y a un nivel de detalle individual.

1.2 OBJETIVOS DEL PROYECTO

El objetivo general del trabajo es **diseñar y validar una metodología para analizar la relación entre el uso del móvil y biomarcadores de bienestar a partir de datos de un wearable, y cuantificar dicha relación de forma estadísticamente honesta.**

Este objetivo general se concreta en los siguientes objetivos específicos:

1. Construir una base de datos unificada que integre las señales fisiológicas del wearable con el registro del uso del móvil, a resolución horaria y diaria.

2. Definir un índice de bienestar objetivo y reproducible a partir de las señales fisiológicas.

3. Aumentar la base de datos mediante técnicas que preserven la estructura temporal real y que permitan simular variabilidad entre individuos.

4. Identificar qué señales fisiológicas son más adecuadas para estudiar la relación entre el uso del móvil y el bienestar.

5. Desarrollar y comparar modelos que midan el efecto del uso del móvil sobre el bienestar, controlando los factores de confusión.

6. Extraer conclusiones honestas sobre la magnitud y la dirección de ese efecto, reconociendo las limitaciones del estudio.

Estos objetivos comparten un hilo conductor: priorizar la honestidad metodológica sobre la búsqueda de un resultado llamativo. Antes que demostrar una hipótesis preconcebida, el trabajo busca medir con rigor, separar el efecto real de los factores que lo confunden y

reconocer abiertamente las limitaciones, de modo que las conclusiones, sean del signo que sean, resulten fiables y reproducibles.

1.3 ESTRUCTURA DE LA MEMORIA

La memoria se organiza como sigue. El Capítulo 2 describe las tecnologías empleadas: el wearable y sus sensores, las señales fisiológicas y su significado, y los conceptos de aprendizaje automático y estadística necesarios. El Capítulo 3 revisa el estado de la cuestión, situando el trabajo respecto a la literatura sobre uso del móvil, wearables y bienestar, e identificando los vacíos que justifican el proyecto. El Capítulo 4 define el trabajo: justificación, objetivos medibles, metodología y planificación. El Capítulo 5 detalla el sistema desarrollado: la preparación de los datos, la definición del índice de bienestar, la aumentación de la base de datos y los modelos implementados. El Capítulo 6 presenta el análisis de resultados, siguiendo el orden en que se obtuvieron, e incluye los bloques de día (vigilia) y noche (sueño). El Capítulo 7 recoge las conclusiones, las aportaciones del trabajo y las líneas futuras. Finalmente se incluyen la bibliografía y un anexo sobre la alineación del proyecto con los Objetivos de Desarrollo Sostenible.

Capítulo 2. DESCRIPCIÓN DE LAS TECNOLOGÍAS

En este capítulo se describen las tecnologías y los conceptos en los que se apoya el trabajo, situándolos en su contexto histórico: la captura del uso del móvil, el dispositivo wearable y sus señales, los fundamentos de aprendizaje automático y estadística, las técnicas de aumentación de datos y la definición operativa del bienestar.

2.1 ADQUISICIÓN DEL USO DEL MÓVIL MEDIANTE INTERPRETACIÓN CON IA

Medir cuánto se usa el móvil no es trivial. Durante años solo existían los autoinformes, hasta que en 2018 los sistemas operativos incorporaron herramientas nativas de seguimiento, Tiempo de Uso en iOS y Bienestar Digital en Android, que registran de forma automática el tiempo de pantalla por aplicación y categoría. Estas herramientas, sin embargo, están pensadas para la consulta visual del usuario y no ofrecen una exportación numérica directa.

Para salvar ese obstáculo, en este trabajo se aprovechó un avance reciente: los modelos de inteligencia artificial con capacidad de visión, capaces de leer una imagen y extraer información estructurada. Se proporcionaron a uno de estos modelos las capturas de pantalla de Tiempo de Uso de iOS y se le pidió transcribirlas a datos numéricos: minutos de uso por categoría, redes sociales, entretenimiento, productividad, juegos, viajes y otras, y por franja temporal. Así, una información puramente visual se convirtió en una serie temporal cuantitativa, alineable con las señales del wearable, con la que se construyeron los agregados horario y diario.

2.2 EVOLUCIÓN DE LA MONITORIZACIÓN FISIOLÓGICA Y EL WEARABLE EMPLEADO

La medición continua de señales fisiológicas tiene una larga historia. Los primeros hitos fueron el electrocardiograma a principios del siglo XX y, en los años sesenta, el monitor Holter, que permitió registrar el ritmo cardiaco de forma ambulatoria durante 24 horas. Durante décadas, medir señales como la conductancia de la piel o la variabilidad cardiaca requería equipos de laboratorio voluminosos. La revolución llegó con la miniaturización de sensores y los wearables de consumo (Fitbit, Apple Watch), que llevaron la monitorización a la muñeca de millones de personas, aunque con precisión limitada. En paralelo surgieron los wearables de grado de investigación, como la pulsera Empatica E4 y su sucesora, el EmbracePlus, diseñados específicamente para estudios clínicos y científicos.

La fuente fisiológica de este trabajo es precisamente el Empatica EmbracePlus [5]. Integra varios sensores en un dispositivo de muñeca: un sensor óptico (PPG) que mide el volumen de sangre y del que se derivan la frecuencia cardiaca y su variabilidad; unos electrodos de EDA que miden la conductancia de la piel; un acelerómetro triaxial para el movimiento y la actividad; y un termómetro de temperatura periférica. A partir de estos sensores, el dispositivo entrega un conjunto de biomarcadores digitales agregados a resolución de un minuto.

2.3 LAS SEÑALES DEL WEARABLE

De cada jornada se obtiene un fichero por señal. Las dieciséis señales utilizadas, con una descripción breve, son las siguientes:

1- **Pulse rate (frecuencia cardiaca):** latidos por minuto, obtenida del sensor óptico (PPG).
2- **PRV (variabilidad del pulso):** variabilidad entre latidos; proxy de la HRV e indicador de recuperación y equilibrio del sistema nervioso autónomo.

3- **EDA (actividad electrodérmica):** conductancia de la piel (µS); refleja la activación (arousal) del sistema nervioso simpático.
4- **Temperatura cutánea:** temperatura de la piel (°C).
5- **Respiratory rate (frecuencia respiratoria):** respiraciones por minuto.
6- **Acelerómetros (desviación estándar):** variabilidad del acelerómetro triaxial; mide el movimiento.
7- **Activity counts / Actigraphy counts / Acticounts:** distintos recuentos de actividad física derivados del acelerómetro.
8- **Activity intensity (intensidad de actividad):** nivel de esfuerzo (sedentario, ligero, moderado o vigoroso).
9- **Activity classification (clasificación de actividad):** tipo de actividad detectada.
10- **MET (equivalente metabólico):** estimación del gasto energético.
11- **Step counts (pasos):** número de pasos.
12- **Body position (posición corporal):** postura del usuario.
13- **Sleep detection (detección de sueño):** identifica los periodos y fases de sueño.
14- **Wearing detection (detección de uso):** indica si el dispositivo se lleva puesto, clave para validar la cobertura de cada día.

2.4 SEÑALES FISIOLÓGICAS Y SU RELACIÓN CON EL BIENESTAR

No todas las señales pesan igual para estudiar el bienestar. La frecuencia cardiaca (HR) refleja el trabajo del corazón; en reposo, valores más bajos suelen indicar mejor condición, pero sube con cualquier esfuerzo físico, por lo que está muy influida por la actividad. La variabilidad del ritmo cardiaco (HRV) mide las pequeñas diferencias de tiempo entre latidos: depende del equilibrio entre los sistemas nerviosos simpático (acelerador) y parasimpático (freno), y es uno de los marcadores más reconocidos de recuperación y estrés. La actividad electrodérmica (EDA) mide la conductancia de la piel, regulada por las glándulas sudoríparas bajo control simpático; es el indicador más directo de arousal o activación y, a diferencia de la HR, apenas se ve afectada por el movimiento. La frecuencia respiratoria se eleva con la activación y el esfuerzo. La temperatura cutánea sigue un marcado ritmo

circadiano. El sueño, cantidad, eficiencia y fases, es uno de los determinantes más fuertes del bienestar, y la actividad física (pasos, MET, minutos de actividad) se relaciona positivamente con él, además de ser un factor de confusión clave sobre las señales cardiovasculares.

No todas pudieron analizarse con la misma fiabilidad: la HRV y la respiración presentaron una cobertura baja durante la vigilia, son muy sensibles al movimiento, por lo que se trataron como secundarias, mientras que la HR, la EDA, la temperatura y la actividad mantuvieron cobertura alta.

2.5 APRENDIZAJE AUTOMÁTICO Y ESTADÍSTICA

El aprendizaje automático es la rama de la inteligencia artificial que estudia algoritmos capaces de aprender patrones a partir de datos en lugar de seguir reglas programadas. Su historia es la de una sucesión de auges y estancamientos. Sus raíces están en 1943, con el modelo de neurona artificial de McCulloch y Pitts [8], y en 1958, con el Perceptrón de Rosenblatt [15], el primer algoritmo capaz de aprender a clasificar. Tras un primer entusiasmo llegó el primer invierno de la IA en los años setenta, al chocar con los límites de aquellos modelos. En los ochenta resurgió con el algoritmo de retropropagación y los sistemas expertos; en los noventa se consolidó el aprendizaje estadístico, con las máquinas de vectores soporte, y, en 2001, Breiman introdujo los Random Forests [3]. El punto de inflexión definitivo llegó en 2012, cuando el aprendizaje profundo ganó la competición de reconocimiento de imágenes ImageNet, desatando la revolución actual que hoy alcanza a los grandes modelos de lenguaje y de visión. Estas técnicas están hoy presentes en la medicina, las finanzas, el reconocimiento de voz e imagen o los sistemas de recomendación.

En este trabajo se emplean técnicas elegidas según el objetivo de cada análisis. La regresión lineal y la correlación miden la asociación entre variables; la correlación parcial la aísla controlando una tercera, clave para separar el efecto del móvil del de la actividad. Los Random Forest y Gradient Boosting son conjuntos de árboles que capturan relaciones no lineales y miden la importancia de cada variable. Los modelos de efectos mixtos tratan

correctamente datos con varias observaciones por individuo. Y la inferencia bayesiana estima la distribución completa de un efecto, cuantificando su incertidumbre, lo que es esencial cuando se trabaja con pocos datos.

2.6 AUMENTACIÓN DE BASES DE DATOS

Los modelos necesitan un volumen de datos suficiente para producir estimaciones fiables. La aumentación de datos, ampliar artificialmente una base preservando sus propiedades, es una práctica consolidada: en visión por computador, por ejemplo, se rotan o recortan imágenes para multiplicar los ejemplos, y en los últimos años las redes generativas y los datos sintéticos se han convertido en un campo de investigación propio. En series temporales fisiológicas no se pueden recombinar observaciones al azar, porque se destruiría la continuidad temporal. Por ello se emplean dos familias de técnicas, siguiendo la taxonomía de Pérez et al. (2024) [13]: el Moving Block Bootstrap, que remuestrea bloques de observaciones consecutivas conservando la dependencia temporal real; y las redes bayesianas con modelos causales (DAG), que generan sujetos virtuales coherentes con una hipótesis. Esta segunda conlleva una cautela importante: como la hipótesis se introduce en la estructura del grafo, los datos sintéticos validan el método, pero no constituyen una prueba independiente de la hipótesis. El detalle se desarrolla en el Capítulo 5.

2.7 DEFINICIÓN OPERATIVA DEL BIENESTAR

El bienestar es un concepto amplio y subjetivo, por lo que el primer reto del trabajo fue traducirlo a algo medible y reproducible a partir de señales fisiológicas. La decisión de partida fue que ningún biomarcador por sí solo equivale al bienestar: una buena HRV, un sueño suficiente o una frecuencia cardiaca en reposo adecuada describen, cada uno, una faceta distinta. Por ello se optó por construir un índice compuesto que integrara varias señales.

El criterio adoptado fue evaluar, para cada día, si cada biomarcador se encontraba dentro de un rango saludable definido a partir de referencias clínicas. Cada señal aporta un voto de

salud, y la combinación produce una puntuación diaria que clasifica las jornadas en baja, media o alta. Esta aproximación por umbrales es transparente e interpretable, aunque relativamente gruesa; por ello se complementó con una versión continua del índice, más sensible. La construcción detallada de ambos se presenta en el Capítulo 5.

Capítulo 3. ESTADO DE LA CUESTIÓN

La monitorización del bienestar mediante dispositivos personales es un campo activo y en rápida evolución, en la intersección de la salud digital, la fisiología y la ciencia de datos. Este capítulo revisa el estado de la cuestión en cinco frentes, wearables y biomarcadores, uso del móvil y bienestar, sueño, estudios de un solo sujeto y aumentación de datos, y termina identificando los vacíos que justifican el trabajo.

3.1 WEARABLES Y BIOMARCADORES DE BIENESTAR

El uso de wearables para cuantificar el estado fisiológico ha crecido enormemente en la última década, impulsado por la miniaturización de los sensores y por dispositivos de grado de investigación capaces de registrar señales antes reservadas al laboratorio. Entre los biomarcadores, la variabilidad del ritmo cardiaco (HRV) se ha consolidado como uno de los más usados: refleja el equilibrio del sistema nervioso autónomo y se asocia de forma robusta con el estrés, la recuperación y la salud mental [19]. La actividad electrodérmica (EDA) es, junto a la frecuencia cardiaca, uno de los indicadores más fiables de arousal y estrés agudo, al reflejar directamente la activación del sistema nervioso simpático mediante la sudoración [2].

Ahora bien, llevar estas medidas del laboratorio a la vida cotidiana introduce dificultades importantes. La literatura de validación señala que la EDA y la HRV captadas en la muñeca pueden ser poco fiables en condiciones de vida libre, especialmente en presencia de movimiento, que degrada la calidad de la señal [9]. Esta limitación, lejos de ser anecdótica, condiciona qué señales pueden sostener conclusiones sólidas y es directamente relevante para este trabajo, donde precisamente la HRV y la respiración mostraron una cobertura baja durante las horas de vigilia.

3.2 USO DEL MÓVIL, SENSADO PASIVO Y BIENESTAR DIGITAL

El smartphone se ha convertido en una fuente de datos para inferir comportamiento y salud mental mediante sensado pasivo (passive sensing): patrones de uso, sueño, movilidad y contexto social. Trabajos pioneros como el estudio SNAPSHOT cruzaron sensores de wearable y móvil con autoinformes de estrés y estado de ánimo en cientos de participantes [17], y proyectos a gran escala como el Google Health Digital Well-Being Study, con más de cuatro mil participantes, buscan relacionar el uso del dispositivo con medidas objetivas y subjetivas de bienestar.

Sin embargo, el hallazgo más relevante de esta literatura es que los efectos del uso del móvil sobre el bienestar son sorprendentemente pequeños y dependientes del método de análisis. En un estudio de referencia sobre más de 350.000 adolescentes, Orben y Przybylski (2019) [11] emplearon el análisis de curva de especificación para mostrar que el uso de tecnología digital explica, como mucho, el 0,4 % de la variación del bienestar, un efecto minúsculo, y que con los mismos datos pueden obtenerse asociaciones positivas, negativas o nulas según las decisiones del analista. Este trabajo ilustra el riesgo de los grados de libertad del investigador y la necesidad de análisis honestos y transparentes.

A esta fragilidad se suma un problema de medición: gran parte de la evidencia se apoya en uso autoinformado, que correlaciona pobremente con el uso real registrado por el dispositivo [4]. Ambos factores, efectos pequeños y medidas subjetivas poco fiables, motivan precisamente el enfoque de este trabajo: medir el uso de forma objetiva y cruzarlo con biomarcadores fisiológicos, controlando los factores de confusión.

3.3 USO NOCTURNO DEL MÓVIL Y SUEÑO

La relación entre el uso del móvil y el sueño es uno de los temas más estudiados. Revisiones sistemáticas recientes concluyen que el uso del smartphone, especialmente antes de dormir, se asocia a peor calidad y menor duración del sueño [7]. Se proponen dos mecanismos: la supresión de melatonina por la luz azul de la pantalla, que retrasa el inicio del sueño, y la

activación psicológica (arousal) provocada por contenidos emocionalmente estimulantes o por los videojuegos. Estudios en jóvenes y estudiantes encuentran que más de sesenta minutos de uso en la cama elevan significativamente el riesgo de mala calidad del sueño. No obstante, buena parte de esta evidencia es transversal y se basa en autoinformes, por lo que la dirección de la causalidad y su magnitud real siguen abiertas.

3.4 ESTUDIOS DE UN SOLO SUJETO Y DIGITAL PHENOTYPING

Frente a los grandes estudios poblacionales, el digital phenotyping, la cuantificación momento a momento del fenotipo humano a nivel individual en su entorno real, habilita estudios N=1 o de un solo sujeto, donde el individuo es la única unidad de observación [10]. Este enfoque, heredero de los diseños N-of-1 de la medicina, permite detectar patrones que se diluyen en los promedios poblacionales y resulta especialmente útil para la monitorización personalizada y la salud de precisión. Su contrapartida es doble: una menor generalización de las conclusiones y unos retos estadísticos derivados del reducido tamaño muestral, que obligan a técnicas específicas para extraer conclusiones fiables.

3.5 AUMENTACIÓN Y GENERACIÓN DE DATOS SINTÉTICOS EN SEÑALES FISIOLÓGICAS

La escasez de datos es un problema central en el aprendizaje automático con señales fisiológicas, por motivos de privacidad y por el reducido número de sujetos disponibles. Para mitigarlo se han desarrollado numerosas técnicas de aumentación de datos para series temporales, organizadas en taxonomías que distinguen transformaciones aleatorias, mezcla de patrones y modelos generativos [6]. Entre los métodos que preservan la dependencia temporal destaca el bootstrap por bloques [14], que remuestrea segmentos consecutivos en lugar de observaciones sueltas. En la línea de la generación probabilística de datos sintéticos coherentes con una hipótesis se sitúa el marco de Pérez et al. (2024), que combina remuestreo y modelos generativos basados en redes bayesianas y que sirve de base metodológica a este trabajo. La principal cautela de estas técnicas es que los datos generados a partir de una

hipótesis solo validan el método y aportan potencia, pero no constituyen evidencia independiente de la propia hipótesis.

3.6 COMPARATIVA DE TRABAJOS PREVIOS

La Tabla 1 resume los trabajos más representativos y los sitúa frente al presente TFG.

Trabajo	**Sujetos**	**Señales / datos**	**Enfoque**	**Limitación principal**
Sano et al. (2018), SNAPSHOT	~200	Wearable + móvil + autoinforme	Marcadores de estrés/salud mental	Depende de autoinformes
Orben y Przybylski (2019)	>350.000	Encuestas de uso y bienestar	Magnitud del efecto (curva de especificación)	Transversal y autoinformado
Ellis et al. (2019)	Lab + app	Uso autoinformado vs real	Validez de la medida de uso	El autoinforme predice mal el uso real
Kumar et al. (2025)	Meta-análisis	Uso móvil + sueño	Revisión sistemática del sueño	Mayoría transversal/autoinforme
Menghini et al. (2019)	Laboratorio	HRV + EDA	Fiabilidad del sensor	EDA/HRV poco fiables con movimiento
Pérez et al. (2024)	Sintético	Series temporales	Datos sintéticos probabilísticos	Validez depende de la hipótesis
Este TFG	**1 (+ aumentado)**	**16 señales wearable + uso móvil**	**Efecto móvil↔bienestar, N=1 + aumentación**	**Generalización limitada**

Tabla 1. Comparativa de trabajos previos sobre uso del móvil, wearables y bienestar.

3.7 VACÍOS IDENTIFICADOS QUE JUSTIFICAN EL TRABAJO

De la revisión anterior se desprenden cuatro huecos que este trabajo aborda. Primero, la mayor parte de la evidencia sobre móvil y bienestar se basa en autoinformes, no en biomarcadores objetivos medidos de forma continua, y, además, el uso autoinformado correlaciona mal con el real. **Segundo**, los grandes estudios poblacionales promedian el

efecto y pierden la dinámica individual; faltan análisis N=1 intensivos que crucen uso del móvil y fisiología en la vida real. **Tercero**, el tamaño muestral reducido de los estudios de un solo sujeto rara vez se aborda con técnicas de aumentación rigurosas que preserven la estructura temporal. Y **cuarto**, dado que los efectos descritos son pequeños y muy sensibles a las decisiones de análisis, son pocos los trabajos que distinguen explícitamente el efecto del móvil de sus factores de confusión, en especial la actividad física, lo que conduce a conclusiones frágiles. Este trabajo se sitúa en la intersección de estos cuatro vacíos.

Capítulo 4. DEFINICIÓN DEL TRABAJO

4.1 JUSTIFICACIÓN

La justificación del trabajo es a la vez técnica, científica y social. Desde el punto de vista social, existe una preocupación legítima sobre el impacto del uso del móvil en el bienestar, pero la evidencia disponible es mayoritariamente subjetiva; aportar una metodología basada en biomarcadores objetivos tiene valor para la salud digital. Desde el punto de vista científico, los estudios poblacionales promedian el efecto y pierden la dinámica individual, mientras que los estudios de un solo sujeto rara vez aplican técnicas estadísticas robustas. Desde el punto de vista técnico, el trabajo integra captura multimodal de datos, ingeniería de datos, aumentación de series temporales y modelado estadístico avanzado, lo que lo convierte en un ejercicio de ingeniería completo.

La principal decisión de diseño del proyecto fue trabajar con un único sujeto monitorizado de forma intensiva (N=1) en lugar de una muestra amplia. Esta decisión responde a la disponibilidad de un wearable de grado de investigación y a la voluntad de capturar la fisiología real en la vida cotidiana con alta resolución. Tiene una contrapartida evidente, la limitada generalización de las conclusiones, y un reto estadístico, el reducido tamaño muestral, que se aborda mediante técnicas de aumentación de datos. Asumir y tratar honestamente estas limitaciones, en lugar de ocultarlas, es parte central de la aportación del trabajo.

4.2 OBJETIVOS MEDIBLES

Los objetivos del proyecto se concretan en metas verificables:

1. Integración de datos: construir una base unificada de wearable y uso del móvil a resolución horaria y diaria, con una cobertura efectiva del wearable superior al 70 % en los días considerados válidos.

2. Índice de bienestar: definir un índice reproducible que pueda recalcularse de forma determinista a partir de las señales, reproduciéndolo en el 100 % de los días.

3. Aumentación: ampliar la base de datos al menos un orden de magnitud preservando las distribuciones reales, validado mediante el test de Kolmogórov–Smirnov.

4. Selección de señal: identificar, con criterios cuantitativos, el biomarcador más adecuado para relacionar móvil y bienestar.

5. Modelado del efecto: estimar el efecto del uso del móvil sobre el bienestar con su intervalo de confianza, controlando los factores de confusión.

6. Conclusión honesta: reportar la magnitud, la dirección y la incertidumbre del efecto, reconociendo las limitaciones.

Por último, al tratarse de datos personales de salud de un único participante, el trabajo asume requisitos de privacidad: los datos corresponden a un sujeto que participa de forma voluntaria e informada y se manejan de forma anonimizada.

Desde el punto de vista técnico, el sistema se diseñó para ser reproducible y de bajo coste: todo el procesamiento se implementó en Python con bibliotecas de código abierto (pandas, scikit-learn [12], statsmodels [18], PyMC [16]), con semilla aleatoria fija, y el cómputo se realiza en un equipo personal sin necesidad de infraestructura especializada.

4.3 REQUISITOS DEL SISTEMA

El sistema impone varios requisitos. En cuanto a los datos, exige un registro fisiológico continuo y de calidad, con cobertura suficiente del wearable, y un registro paralelo del uso del móvil, ambos con marca temporal para poder alinearlos. La pérdida de cobertura en las señales más sensibles al movimiento, como la HRV y la respiración, obligó a establecer criterios de calidad y a tratar esas señales como secundarias.

4.4 METODOLOGÍA

El trabajo sigue un pipeline estructurado en fases sucesivas:

1. Captura de datos. registro fisiológico continuo con el wearable Empatica EmbracePlus y registro del uso del móvil mediante capturas de Tiempo de Uso interpretadas con un modelo de IA con visión.

2. Procesamiento e integración. limpieza, control de cobertura, agregación a resolución horaria y diaria, y unión de ambas fuentes en una base de datos común.

3. Definición del bienestar. construcción del índice de bienestar a partir de umbrales clínicos sobre las señales.

4. Análisis exploratorio. regresión lineal simple y análisis de series temporales para validar la calidad de los datos e identificar patrones e hipótesis.

5. Aumentación de la base de datos. aplicación de Moving Block Bootstrap, que preserva la estructura real, y generación de sujetos sintéticos mediante una red bayesiana con modelo causal, que aporta variabilidad entre individuos, con su validación estadística.

6. Modelado. comparación de modelos predictivos, validación bayesiana de la recuperación del efecto y construcción del modelo explicativo final con el uso del móvil como variable independiente.

7. Análisis por bloques. estudio diferenciado de los bloques de día (vigilia, canal de arousal) y noche (sueño), y del uso por categorías de aplicación.

8. Síntesis y conclusiones. integración de los resultados y extracción de conclusiones honestas.

4.5 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

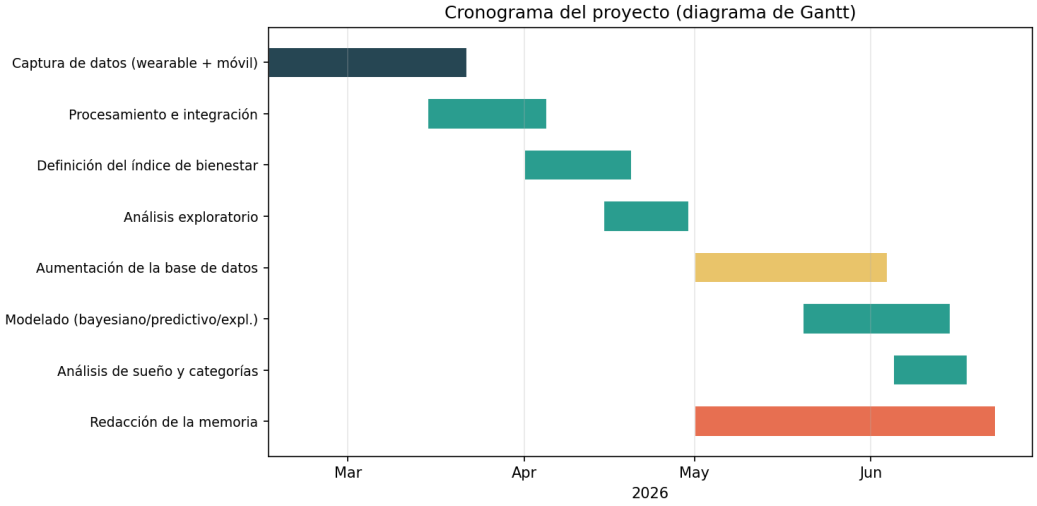


Figura 1. Cronograma del proyecto (diagrama de Gantt).

El proyecto se organizó en las fases descritas en la metodología, cuyo desarrollo temporal se resume en el cronograma de la Figura 1, y cada una presentó sus propias dificultades. En la captura de datos, el principal problema fue la cobertura del wearable: algunos días el dispositivo no se llevó de forma continua o se quedó sin batería, lo que obligó a descartar las jornadas con cobertura insuficiente; en el lado del móvil, la ausencia de una exportación numérica directa obligó a recurrir a la interpretación de las capturas de Tiempo de Uso mediante IA. En el procesamiento e integración, la dificultad fue alinear temporalmente dos fuentes muy distintas y homogeneizarlas a franjas horarias comunes. En la aumentación de la base de datos, el reto fue elegir las técnicas adecuadas y realizar una investigación sobre cuáles nos aportaban más en este tipo de estudio. Finalmente, en el modelado, la principal dificultad fue detectar la circularidad del primer enfoque predictivo y reorientar el trabajo hacia un modelo explicativo, además de separar el efecto real del móvil del factor de confusión de la actividad física. La redacción de la memoria se intercaló con el trabajo técnico para no acumularla al final.

En cuanto a los recursos, el proyecto fue posible gracias al CIHS y, muy especialmente, a Lucía, que cedió el wearable Empatica EmbracePlus para su uso durante el estudio; sin ese

dispositivo el trabajo no habría sido viable. Toda la pila de software empleada es de código abierto (Python y sus librerías científicas) y el cómputo se realizó en un equipo personal, de modo que no hubo costes de licencias ni de infraestructura. El esfuerzo del proyecto se concentra, por tanto, en las horas de dedicación: aproximadamente unas cuatrocientas horas de trabajo del alumno, repartidas entre la captura y preparación de los datos, el análisis y el modelado, y la redacción de la memoria, a las que se suman las horas de supervisión y orientación de los tutores.

A título orientativo, el esfuerzo se concentró en cuatro frentes: la captura y preparación de los datos, el análisis y el modelado, que fue la fase más intensiva, la redacción de la memoria, y la supervisión y reuniones con los tutores, lo que suma del orden de las cuatrocientas horas mencionadas.

Capítulo 5. SISTEMA/MODELO DESARROLLADO

5.1 ARQUITECTURA GENERAL DEL SISTEMA

El sistema desarrollado es un pipeline de análisis de datos que parte de dos fuentes heterogéneas, la señal fisiológica de un wearable y el registro del uso del móvil, y las transforma, paso a paso, hasta obtener una medida cuantitativa de la relación entre ambos. El flujo consta de seis etapas encadenadas: extracción y preparación de los datos de ambas fuentes; definición de un índice de bienestar a partir de las señales; análisis exploratorio para validar la calidad de los datos y formular hipótesis; aumentación de la base de datos para ganar potencia estadística; modelado del efecto del uso del móvil sobre el bienestar; y análisis específicos por bloques de día, noche y categoría de uso.

Los requisitos del sistema fueron tres: reproducibilidad, ya que todo el procesamiento se implementó con semilla fija y es recreable; trazabilidad, pues cada fase genera resultados intermedios que pueden inspeccionarse; y robustez frente al tamaño muestral, dado que el diseño asume desde el inicio que se trabaja con un único sujeto y pocos días, lo que condiciona las técnicas empleadas. La Figura 2 resume la arquitectura del pipeline.

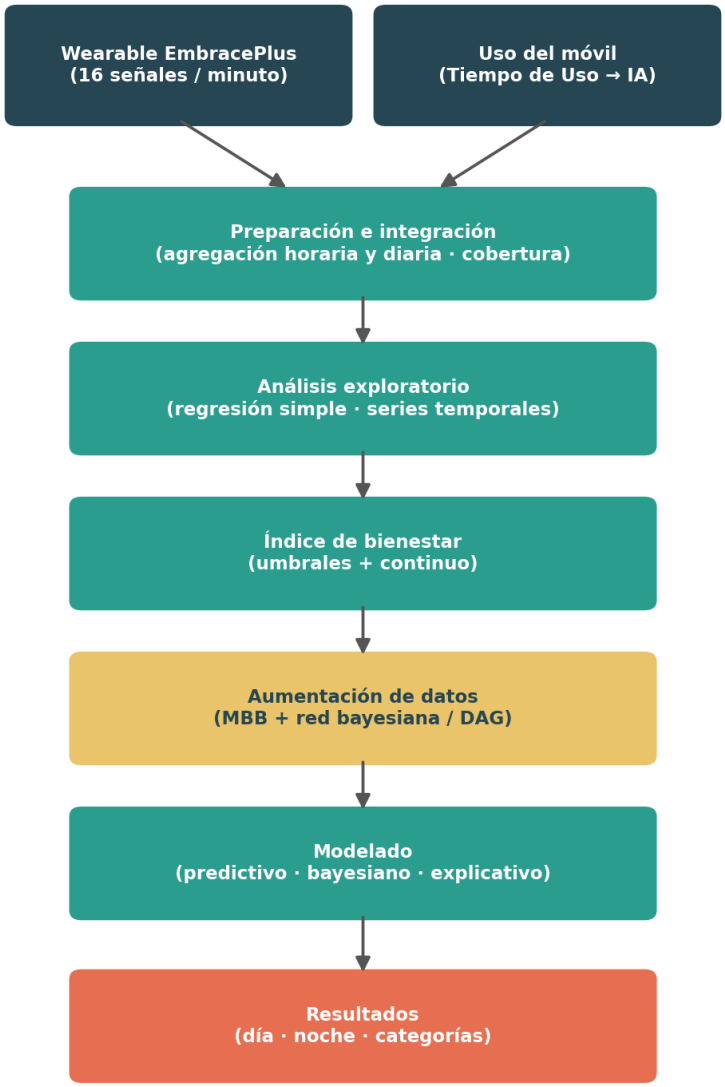


Figura 2. Arquitectura del pipeline: de las dos fuentes de datos a los resultados.

5.2 EXTRACCIÓN Y PREPARACIÓN DE LOS DATOS

5.2.1 DATOS FISIOLÓGICOS DEL WEARABLE

La señal fisiológica procede del Empatica EmbracePlus. Los datos se entregaron en una estructura de carpetas organizada por fecha y participante, en la que cada día contiene un fichero por señal con los valores agregados a resolución de un minuto (marca de tiempo y

valor). En total se manejan las dieciséis señales descritas en el Capítulo 2: frecuencia cardiaca, PRV, EDA, temperatura, respiración, acelerómetros, recuentos de actividad, MET, pasos, posición corporal, y detección de sueño y de uso del dispositivo.

El primer paso fue unificar esa multitud de ficheros: el archivo comprimido entregado por el wearable contiene cientos de tablas, por lo que se leyeron, se alinearon por marca de tiempo y se construyeron tablas derivadas más manejables. A partir de los datos por minuto se generaron dos niveles de agregación, uno horario y otro diario, calculando promedios para las señales continuas (frecuencia cardiaca, variabilidad cardiaca, EDA, temperatura, respiración y MET) y sumas para las acumulativas (pasos, minutos de sueño y de actividad). La señal de detección de uso del dispositivo se empleó para calcular la cobertura de cada día, es decir, el porcentaje de tiempo en que el wearable se llevó efectivamente puesto.

5.2.2 DATOS DE USO DEL MÓVIL

El uso del teléfono se obtuvo a partir de las capturas de pantalla de la función Tiempo de Uso (Screen Time) de iOS. Como estas gráficas no permiten una exportación numérica directa, se empleó un modelo de inteligencia artificial con capacidad de visión que interpretó cada captura y la transcribió a datos estructurados: minutos de uso desglosados por categoría, redes sociales, entretenimiento, productividad, juegos, viajes y otras, y por franja temporal. El resultado se organizó en dos tablas análogas a las del wearable, una horaria y otra diaria, lo que permite cruzar el uso del móvil con la fisiología tanto a nivel de día como de hora.

5.2.3 INTEGRACIÓN Y CONTROL DE CALIDAD

Ambas fuentes se unieron por fecha y franja horaria en una base de datos común, generando tres tablas: una diaria, una horaria completa de veinticuatro horas y una horaria restringida a las horas de vigilia, esta última pensada para los análisis que no dependen del sueño.

El control de calidad se basó en la cobertura del wearable. La cobertura efectiva media fue alta, del 86,6 %, con dos días claramente por debajo del umbral del 70 %: el 12 de marzo (40,6 %, primer día de uso, en el que el dispositivo aún no se llevaba de forma continua) y el 22 de marzo (39,6 %, último día). Este último se excluyó del análisis para evitar sesgos,

dejando un total de diez días útiles. Este número reducido de jornadas es, precisamente, lo que motiva la fase posterior de aumentación de la base de datos.

5.2.4 DIVISIÓN EN BLOQUES DE DÍA Y NOCHE

La preparación de los datos en una tabla completa de veinticuatro horas y otra restringida a la vigilia anticipa una decisión que estructura todo el análisis posterior: la separación entre un bloque de día (vigilia) y un bloque de noche (sueño). Esta división responde a tres razones.

Fisiológica. El cuerpo se comporta de forma radicalmente distinta despierto que dormido: de noche, la frecuencia cardiaca, la temperatura y la actividad caen por el ritmo circadiano, no por el uso del móvil. Mezclar ambos periodos confundiría el efecto del móvil con el efecto natural del ciclo día-noche.

De mecanismo. El móvil puede afectar al bienestar por dos vías distintas, cada una activa en un periodo. De día, el mecanismo plausible es la activación aguda (arousal): usar el móvil eleva momentáneamente la activación simpática (EDA, frecuencia cardiaca). De noche, el mecanismo es indirecto y diferido: el uso del móvil a última hora afecta al sueño, y el sueño afecta al bienestar del día siguiente.

De datos. El sueño solo puede estudiarse de forma fiable sobre los datos reales; además, como se verá, la base de datos aumentada se construye a partir de horas de vigilia. Por ello el bloque de día se analiza sobre la base ampliada, con toda su potencia, mientras que el bloque de noche se analiza sobre los datos reales.

Siguiendo esta lógica, los análisis del bloque de día se presentan en el apartado 5.6 y los del bloque de noche en el apartado 5.7.

5.3 ANÁLISIS EXPLORATORIO INICIAL

Antes de aumentar la base de datos se realizó un análisis exploratorio con dos objetivos: validar la calidad de los datos y formular hipótesis que orientaran el modelado posterior. Se

emplearon dos herramientas: una regresión lineal simple y la representación de las series temporales diarias.

5.3.1 REGRESIÓN LINEAL SIMPLE

Como primer tanteo de la relación entre el móvil y la fisiología se ajustó una regresión lineal simple entre el uso diario del móvil y la frecuencia cardiaca media, sobre los diez días útiles. Se eligió la frecuencia cardiaca por ser uno de los biomarcadores más robustos y mejor cubiertos. La Figura 3 muestra el resultado.

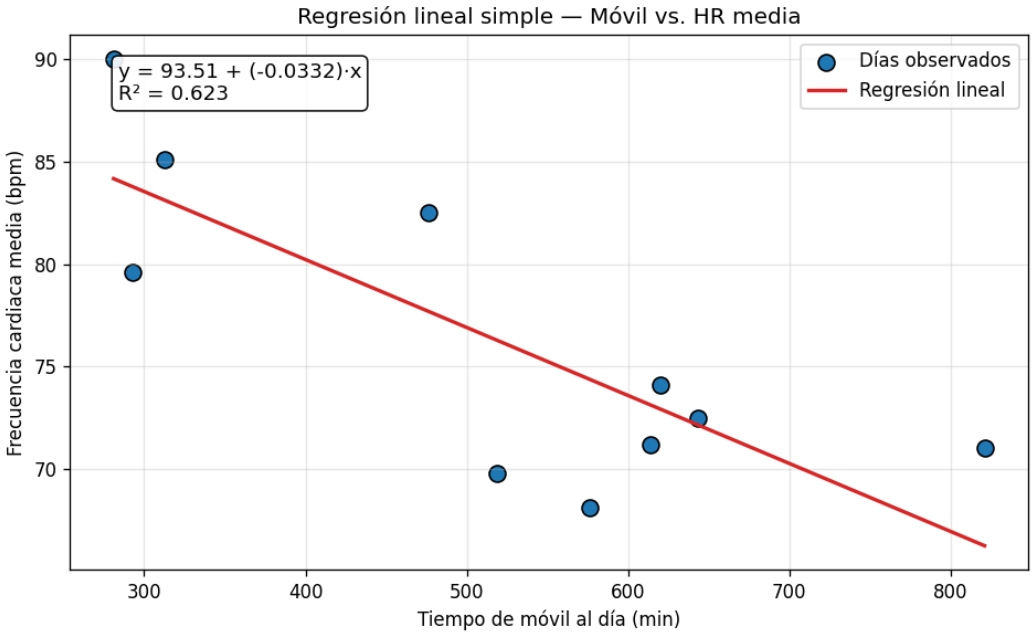


Figura 3. Regresión lineal simple entre el uso del móvil y la frecuencia cardiaca media.

Cada punto es un día; el eje horizontal es el tiempo de móvil en minutos y el vertical la frecuencia cardiaca media en bpm. La recta ajustada es HR = 93,51 − 0,0332 · móvil, con un coeficiente de determinación $R^2 = 0,62$ y una correlación de Pearson $r = -0,79$ ($p = 0,007$), estadísticamente significativa. Es decir, se observa una relación negativa: los días de más móvil tienden a tener una frecuencia cardiaca media más baja.

Este resultado, aunque llamativo, debe interpretarse con cautela y por eso se trata como meramente exploratorio. Con solo diez días, un único día atípico puede inclinar la recta. Y,

sobre todo, la relación es probablemente espuria: los días de mucho móvil suelen ser días más sedentarios, y menos actividad física implica de por sí una frecuencia cardiaca más baja, de modo que la caída de la HR no la causaría el móvil sino el sedentarismo asociado. Esta observación, la necesidad de controlar la actividad física como factor de confusión, es una de las hipótesis que guiará el modelado posterior.

En términos estadísticos, la actividad física actúa como **factor de confusión** porque influye a la vez en las dos cosas que comparamos: se relaciona con el uso del móvil (los días de más móvil son más sedentarios) y, además, afecta directamente a la fisiología (a menos actividad, menor frecuencia cardiaca). Cuando una tercera variable influye sobre la supuesta causa y sobre el efecto a la vez, crea una asociación aparente entre ambos que no es real; por eso es imprescindible controlarla para no atribuir al móvil un efecto que en realidad es del sedentarismo.

5.3.2 ANÁLISIS DE SERIES TEMPORALES

Para cada día se generó una representación con todas las señales apiladas a lo largo de las veinticuatro horas, compartiendo el mismo eje horario. En la parte superior se muestra el uso del móvil por horas y, debajo, cada biomarcador (frecuencia cardiaca, HRV, EDA, temperatura, respiración, actividad, pasos y MET) y las señales de estado (clasificación de actividad, posición corporal, detección de sueño y de uso del dispositivo). Esta vista permite inspeccionar visualmente la coincidencia temporal entre los picos de uso del móvil y los cambios fisiológicos, y comprobar que el dispositivo registra de forma coherente.

Las Figuras 4 y 5 muestran dos días representativos. El sábado 14 (Figura 4), con 281 minutos de móvil, ejemplifica un día de fin de semana: el uso del teléfono se concentra en la tarde-noche y la hora de dormir se retrasa. El miércoles 18 (Figura 5), con 821 minutos de móvil, ejemplifica un día laborable de uso intenso, más repartido a lo largo de la jornada.

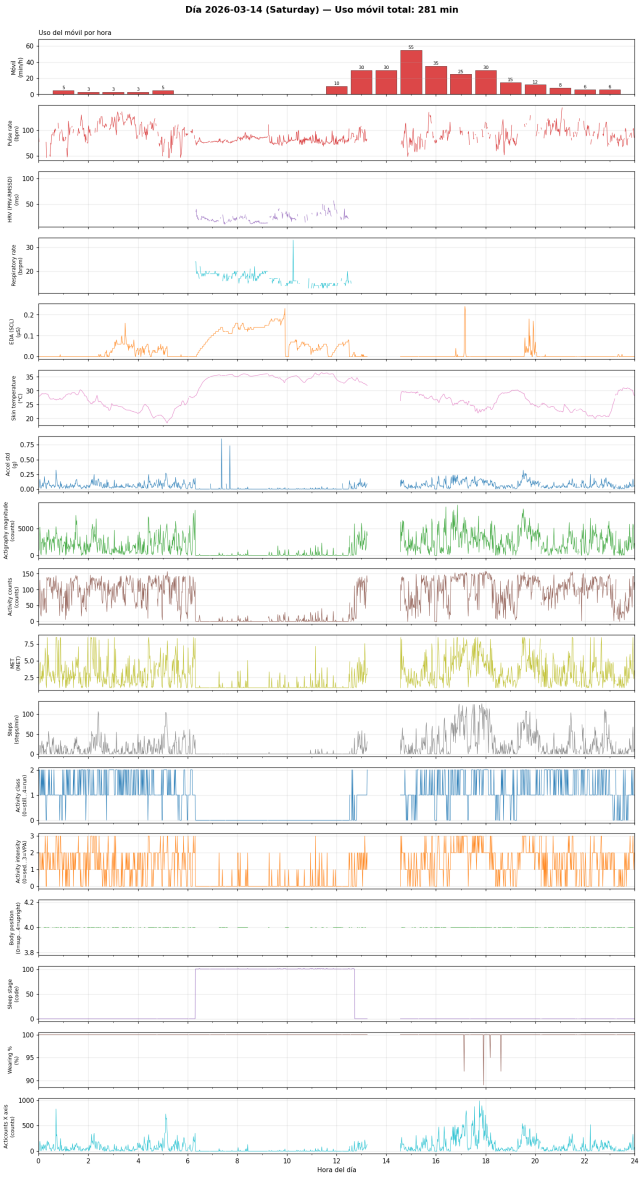


Figura 4. Series temporales del sábado 14 de marzo (fin de semana, 281 min de móvil).

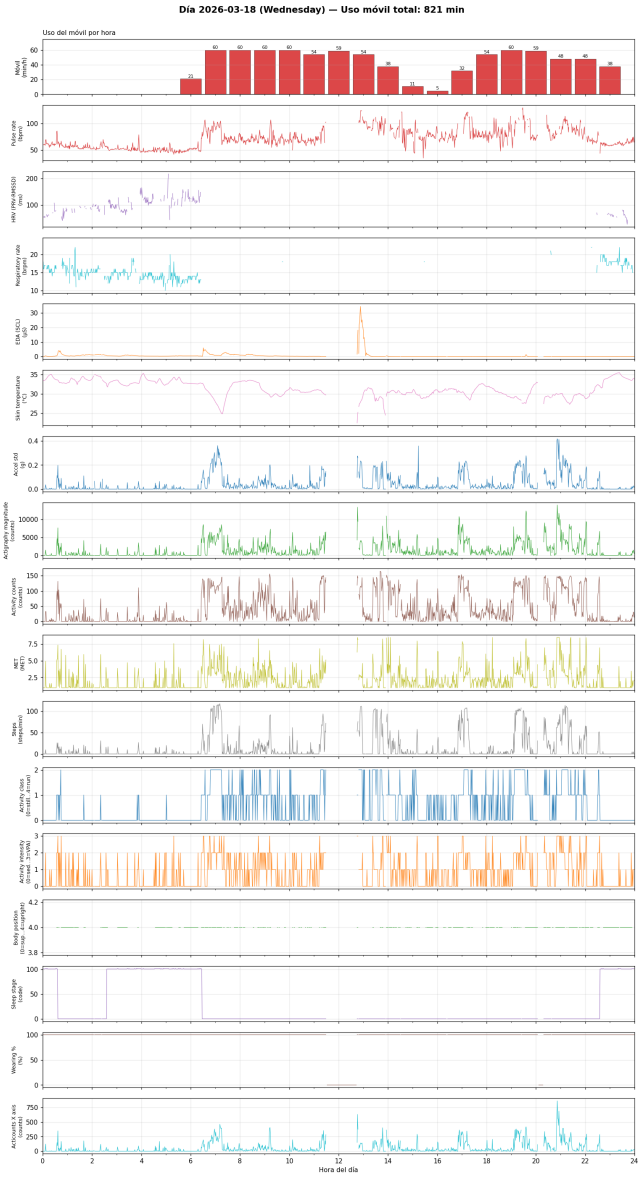


Figura 5. Series temporales del miércoles 18 de marzo (laborable, 821 min de móvil).

En todos los días se observan de forma consistente los mismos patrones, lo que valida la calidad de los datos. En primer lugar, un ritmo circadiano muy marcado en la frecuencia cardiaca, la temperatura, el MET y la actividad: caídas profundas durante la noche y subidas progresivas a lo largo del día. En segundo lugar, el bloque de detección de sueño y la señal de uso del dispositivo se solapan correctamente con las franjas nocturnas, lo que valida internamente la calibración del wearable. Y, en tercer lugar, el uso del móvil presenta dos patrones según el tipo de día: en fin de semana se retrasa la hora de dormir y el uso se alarga

hacia la noche, mientras que en los días laborables se concentra más en las horas de luz. También se confirma visualmente que la HRV y la respiración son las señales con más huecos, reforzando la decisión de tratarlas como secundarias.

En conjunto, el análisis exploratorio cumplió su función: confirmó que los datos son coherentes y de calidad, y dejó planteada la hipótesis central que se abordará con el modelado, esto es, que la relación aparente entre móvil y fisiología puede estar confundida por la actividad física.

5.4 DEFINICIÓN DEL ÍNDICE DE BIENESTAR

5.4.1 ANÁLISIS DE COBERTURA Y CALIDAD DE LAS SEÑALES

Antes de construir el índice fue necesario comprobar qué señales eran realmente utilizables. La cobertura de cada biomarcador, el porcentaje de tiempo con dato válido no es uniforme: depende de la calidad de contacto del sensor y de las condiciones de medida. Analizando las horas de vigilia disponibles se obtuvieron las coberturas de la Tabla 2.

Señal	**Cobertura (vigilia)**
Frecuencia cardiaca (HR)	92 %
EDA	92 %
Temperatura	92 %
MET / actividad	92 %
Respiración	34 %
Variabilidad cardiaca (HRV)	20 %

Tabla 2. Cobertura efectiva de cada señal durante las horas de vigilia.

La frecuencia cardiaca, la EDA, la temperatura y la actividad cuentan con una cobertura alta (en torno al 92 %) y son plenamente fiables. En cambio, la variabilidad cardiaca (20 %) y la frecuencia respiratoria (34 %) presentan una cobertura baja: ambas son muy sensibles al

movimiento, y el wearable de muñeca solo las estima bien en reposo, por lo que durante el día se pierden la mayoría de las muestras. La consecuencia es que no son aptas para alimentar modelos que necesitan muchos datos, como los algoritmos de las fases posteriores, donde tan pocas muestras producirían resultados inestables.

5.4.2 ÍNDICE POR UMBRALES

Como se argumentó en el Capítulo 2, ningún biomarcador aislado equivale al bienestar, por lo que se optó por un índice compuesto. El índice evalúa, para cada día, si seis señales se encuentran dentro de un rango saludable; cada señal aporta un indicador binario (cumple o no cumple) y el índice es el porcentaje de indicadores en verde. Los criterios, definidos a partir de referencias clínicas [1], [19], se recogen en la Tabla 3.

Componente	**Señal**	**Criterio saludable**
Frecuencia cardiaca	HR media diaria	≤ 95 bpm
Variabilidad cardiaca	HRV (RMSSD)	≥ 40 ms
Respiración	Frecuencia respiratoria	≤ 18 rpm
Sueño	Minutos de sueño	≥ 450 min (7,5 h)
Actividad moderada-vigorosa	MVPA	≥ 30 min
Pasos	Pasos totales	≥ 5.000

Tabla 3. Componentes del índice de bienestar y sus umbrales.

Aquí se tomó una decisión importante respecto a la HRV y la respiración. Pese a su baja cobertura, sí se incluyeron como componentes del índice por umbrales, porque al agregar a nivel diario el promedio de las pocas muestras disponibles los valores resultaban fisiológicamente coherentes: eran pocos datos, pero lógicos y consistentes con el resto de la fisiología de cada jornada. Es decir, no bastaban para entrenar algoritmos, donde la escasez de datos sí es un problema, pero sí eran suficientes para un índice descriptivo diario, en el

que cada señal aporta solo un voto de salud. De este modo el índice mantiene las seis dimensiones del bienestar sin renunciar a ninguna.

La puntuación diaria es la media de los seis indicadores expresada en porcentaje (por ejemplo, cinco de seis criterios cumplidos equivalen a un 83,3 %), y cada día se clasifica como bajo, medio o alto. Esta aproximación es transparente: permite ver de un vistazo qué componente falla cada día.

El cálculo del índice está implementado en el código del proyecto de forma determinista y completamente reproducible: a partir de las señales diarias aplica los umbrales de la Tabla 3, obtiene los seis indicadores y calcula la puntuación. Se verificó que reproduce exactamente la puntuación de bienestar en los diez días útiles, con una coincidencia del 100 %. La Figura 6 muestra la evolución diaria del índice.

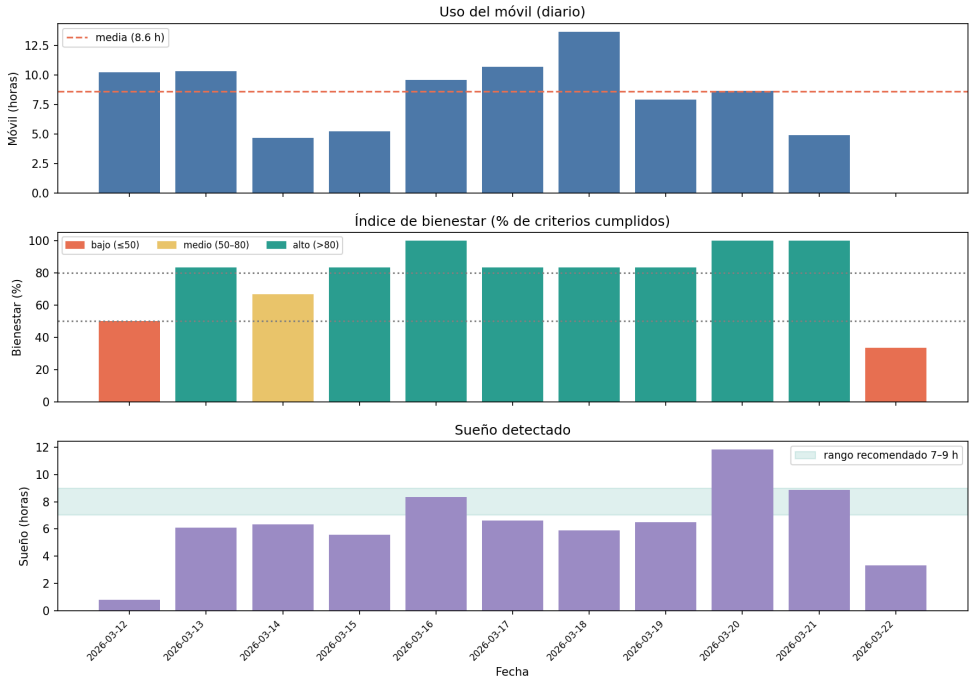


Figura 6. Panel diario: uso del móvil, índice de bienestar y sueño.

La Figura 6 reúne tres gráficas diarias que comparten el eje temporal, lo que permite inspeccionar de un vistazo la relación entre el uso del móvil y la fisiología. El primer panel muestra el uso del móvil en horas, con su media; el segundo, el índice de bienestar coloreado

por categoría (rojo para bajo, amarillo para medio y verde para alto), con los cortes en 50 y 80; y el tercero, las horas de sueño detectado, con el rango recomendado de 7 a 9 horas sombreado. Una primera lectura ya resulta reveladora: los dos días de bienestar bajo (12 y 22 de marzo) coinciden con poco sueño, mientras que el día de mayor uso del móvil (18 de marzo) mantiene un bienestar alto, de modo que a simple vista no se aprecia un patrón de mayor uso del móvil asociado a peor bienestar.

5.4.3 ÍNDICE CONTINUO

El índice por umbrales tiene una limitación: al reducir cada señal a un sí o un no, solo puede tomar unos pocos valores discretos. Esto lo hace poco sensible a los cambios pequeños, ya que dos días distintos pueden obtener la misma puntuación, aunque uno sea fisiológicamente mejor que el otro. Para captar esos matices se definió un índice continuo, también implementado en el código del proyecto.

La idea es sencilla: en lugar de comprobar si cada señal supera un umbral, se mide cuánto se aleja cada día del valor habitual del sujeto, usando la puntuación tipificada o z-score. El z-score de una señal en un día se calcula restándole su media y dividiendo por su desviación típica; el resultado indica, en número de desviaciones, si ese día estuvo por encima o por debajo de lo normal. Un z-score de 0 significa un día típico; +1, un día notablemente mejor de lo habitual; y −1, peor de lo habitual.

Cada señal se tipifica y se orienta para que un valor más alto signifique siempre mejor bienestar: la variabilidad cardiaca, el sueño y los pasos se suman tal cual (cuanto más, mejor), mientras que la frecuencia cardiaca, la respiración y la EDA se restan (cuanto más bajas, mejor, por asociarse a menor activación). La media de todas estas puntuaciones orientadas produce el índice continuo: una única cifra centrada en cero, donde los valores positivos corresponden a días mejores que la media del sujeto y los negativos a días peores.

La ventaja es que es una escala fluida, sin escalones, mucho más sensible para detectar relaciones débiles, como la que se busca entre el uso del móvil y el bienestar. Por eso ambos

índices se usan de forma complementaria a lo largo del trabajo: el de umbrales por su interpretabilidad y el continuo por su sensibilidad.

5.5 AUMENTACIÓN DE LA BASE DE DATOS

5.5.1 MOTIVACIÓN Y ENFOQUE

El análisis exploratorio dejó claro el factor limitante del estudio: con solo diez días útiles de un único sujeto, la potencia estadística es escasa y no es posible aplicar modelos multivariantes ni separar con fiabilidad el efecto del móvil del de sus factores de confusión. La solución fue aumentar la base de datos, es decir, ampliarla artificialmente preservando sus propiedades estadísticas.

El diseño se basó en el marco propuesto por Pérez et al. (2024) [13] en Knowledge-Based Systems, que organiza la generación de datos sintéticos en distintas familias. De ese marco se combinaron dos capas complementarias: una primera que multiplica los datos reales conservando su estructura temporal, sin inventar relaciones, y una segunda que simula sujetos virtuales a partir de un modelo causal explícito. Cada capa cubre una carencia distinta: la primera aporta volumen sin sesgo, y la segunda aporta variabilidad entre individuos.

5.5.2 CAPA 1, MOVING BLOCK BOOTSTRAP

La primera capa emplea el Moving Block Bootstrap (MBB), una variante del bootstrap clásico para series temporales [14]. En lugar de remuestrear observaciones sueltas, lo que destruiría la continuidad fisiológica, extrae bloques de horas consecutivas y los recombina. Así, dentro de cada bloque se conserva intacta la dependencia temporal real, y la aleatoriedad procede solo de cómo se concatenan los bloques.

En términos algorítmicos se empleó la variante estacionaria del bootstrap por bloques de Politis y Romano [14], en la que la longitud de cada bloque no es constante sino aleatoria, con una distribución geométrica de media seis horas. El algoritmo elige una hora de inicio al azar dentro de la serie real y copia observaciones consecutivas; en cada paso decide, con

una probabilidad de uno entre seis, si cierra el bloque y salta a una nueva hora de inicio aleatoria o si continúa copiando la siguiente hora. Como los puntos de inicio son aleatorios pero el interior de cada bloque es real, se conserva intacta la dependencia temporal local y solo se altera la forma en que se enlazan los tramos, lo que además evita que aparezcan artefactos periódicos en los puntos de empalme. El procedimiento es determinista una vez fijada la semilla, de modo que cualquiera puede reproducir exactamente la misma base aumentada.

Sobre los datos reales se aplicaron 30 réplicas. A cada réplica se le añadió después un pequeño ruido multivariante (jitter) del 15 %, calibrado con la covarianza real de cada hora, de modo que las copias conservan las correlaciones entre señales pero no son idénticas entre sí. Por último, todos los valores se recortaron a rangos fisiológicamente posibles: la frecuencia cardiaca entre 35 y 200 bpm, la HRV entre 5 y 250 ms, la EDA entre 0,001 y 25 µS, la temperatura entre 20 y 38 °C, la respiración entre 8 y 30 rpm y el MET entre 0,9 y 8. El resultado son unas 5.130 filas derivadas exclusivamente del sujeto real, sin ninguna hipótesis añadida.

5.5.3 CAPA 2, RED BAYESIANA CON MODELO CAUSAL

La segunda capa genera 25 sujetos virtuales (14 días cada uno, en horas de vigilia) mediante una red bayesiana gaussiana con un modelo causal estructural (DAG). Para cada sujeto se sortean unos rasgos basales propios (su frecuencia cardiaca, HRV, EDA… de referencia) a partir de priors tomados de la literatura clínica (AHA para la frecuencia cardiaca, Shaffer y Ginsberg 2017 para la HRV, Boucsein 2012 para la EDA), lo que genera la variabilidad entre individuos que el dato real no tiene.

En la red bayesiana, cada biomarcador se genera mediante una ecuación lineal que combina una línea base circadiana propia del sujeto, el efecto del arousal —proporcional al uso del móvil y a la sensibilidad de cada sujeto— y un término de ruido gaussiano. Variando los parámetros entre sujetos virtuales se obtiene una cohorte heterogénea pero coherente con la hipótesis.

La clave es que la hipótesis del estudio está escrita en la estructura del grafo: cada hora se genera un uso del móvil, ese uso produce una activación simpática (arousal), y esa activación modifica los biomarcadores según los signos hipotetizados, uso del móvil → arousal → (HR positiva, HRV negativa, EDA positiva, respiración positiva, MET negativa), más un término de ruido. El resultado son unas 5.950 filas. Conviene subrayar la cautela ya mencionada: como el efecto se introduce por diseño, este bloque sirve para validar que el método es capaz de recuperar el efecto si existe y para aportar potencia, pero no como prueba independiente de la hipótesis.

El conjunto de supuestos causales de esta segunda capa se resume gráficamente en la Figura 7.

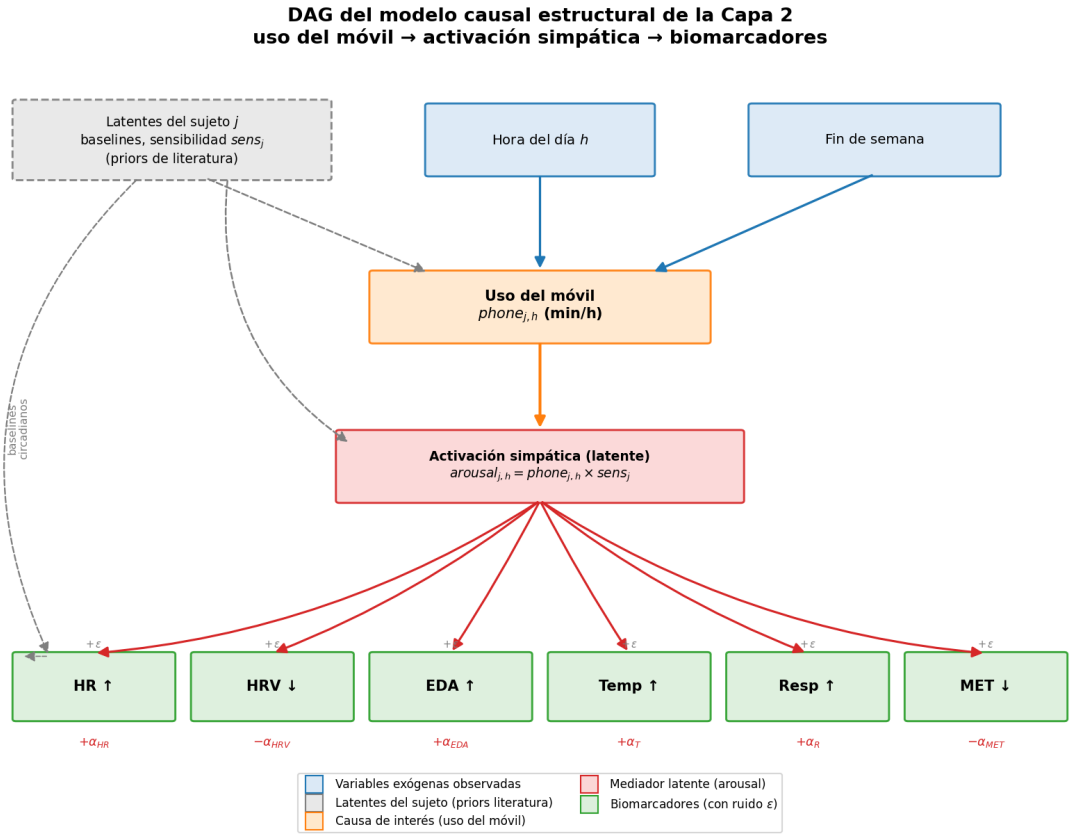


Figura 7. Grafo acíclico dirigido (DAG) del modelo causal estructural de la Capa 2.

En el grafo, las variables exógenas —la hora del día, el fin de semana y los rasgos latentes de cada sujeto, sorteados de los priors de la literatura— determinan el uso del móvil; este

genera una activación simpática latente, igual al producto del uso del móvil por la sensibilidad individual, que a su vez modifica cada biomarcador según un coeficiente con su signo hipotetizado, sumándose una línea base circadiana y un término de ruido gaussiano. La hipótesis del estudio reside así en la estructura del grafo, no en los datos.

Cada uno de los veinticinco sujetos virtuales recibe un conjunto de rasgos basales propios, sorteados una sola vez de distribuciones normales cuyos parámetros provienen de la literatura clínica (Tabla 4). Estos valores de referencia, junto con la sensibilidad simpática individual de cada sujeto, son los que generan la heterogeneidad entre personas de la que carece el dato real, procedente de un único individuo.

Parámetro	**Distribución**	**Truncamiento**	**Fuente**
Baseline HR	N(85, 8) bpm	—	AHA (rango en reposo)
Baseline HRV (RMSSD)	N(80, 25) ms	≥ 20	Shaffer y Ginsberg (2017)
Baseline EDA (SCL)	N(0,3, 0,3) µS	≥ 0,05	Boucsein (2012)
Baseline Temp	N(30,0, 1,5) °C	—	Temp. periférica (wearable)
Baseline Resp	N(16, 2,5) rpm	—	Rango clínico adulto
Baseline MET	N(2,5, 0,5)	≥ 1,0	Compendio de actividad
Sensibilidad simpática (sens)	N(1,0, 0,3)	≥ 0,3	Hiperparámetro adimensional

Tabla 4. Distribuciones a priori de los rasgos basales por sujeto.

El efecto del uso del móvil sobre cada biomarcador se representa mediante un coeficiente que indica cuánto cambia esa señal por cada minuto adicional de móvil, y que también se sortea por sujeto (Tabla 5). Conviene precisar el origen de estos valores, pues es donde reside una matización importante: la dirección de cada efecto —es decir, su signo— está respaldada por la literatura sobre activación simpática, mientras que la magnitud media y su variabilidad constituyen una calibración propia y razonable. La desviación típica de cada coeficiente no

es un capricho, sino que codifica de forma explícita la incertidumbre sobre esa magnitud. Esta distinción es deliberada: el modelo no fija un número exacto extraído de un artículo concreto, sino una distribución que refleja lo que la literatura permite afirmar con seguridad, el signo, y lo que no, el valor preciso.

Coeficiente	**Distribución**	**Signo hipotetizado**
alfa_HR	N(+0,10, 0,05) bpm/min	+
alfa_HRV	N(−0,30, 0,10) ms/min	−
alfa_EDA	N(+0,008, 0,003) µS/min	+
alfa_Temp	N(+0,005, 0,003) °C/min	+
alfa_Resp	N(+0,02, 0,01) rpm/min	+
alfa_MET	N(−0,003, 0,002) /min	−

Tabla 5. Distribuciones a priori de los coeficientes del efecto del móvil (cambio por minuto de uso).

El uso del móvil tampoco es constante a lo largo del día, sino que sigue un perfil horario realista: parte de unos cinco minutos a primera hora de la mañana y crece hasta un máximo en torno a los cincuenta y cinco minutos a las nueve de la noche, con un incremento adicional del veinte por ciento los fines de semana. Sobre ese valor medio horario se añade una variabilidad aleatoria y el resultado se acota entre cero y sesenta minutos por hora.

Con todo ello, cada biomarcador se genera sumando tres componentes: una línea base circadiana propia del sujeto, que reproduce el ritmo natural de subida diurna y caída nocturna; el efecto del arousal, igual al coeficiente correspondiente multiplicado por la activación simpática de esa hora; y un término de ruido gaussiano que introduce la variabilidad residual. La frecuencia cardiaca, la EDA, la temperatura y la respiración crecen con el arousal, mientras que la HRV y el MET disminuyen, de acuerdo con los signos hipotetizados. Igual que en la Capa 1, los valores se recortan a los mismos rangos fisiológicos, y todo el proceso es determinista al fijar la semilla.

5.5.4 RESULTADO Y VALIDACIÓN

La base aumentada final combina las tres fuentes, 171 filas reales, 5.130 del MBB y 5.950 sintéticas, en total unas 11.251 filas horarias, frente a las 171 reales de partida, lo que supone multiplicar los datos por más de sesenta.

Para comprobar que la aumentación es válida se compararon las distribuciones de las tres fuentes mediante el test de Kolmogórov–Smirnov y de forma visual (Figura 8). El resultado confirma la calidad del proceso: el MBB es estadísticamente indistinguible del dato real (valores p superiores a 0,99 en casi todas las señales), como debe ser al proceder de él; y el sintético mantiene medias y rangos fisiológicamente plausibles, aunque con distribuciones algo más estrechas.

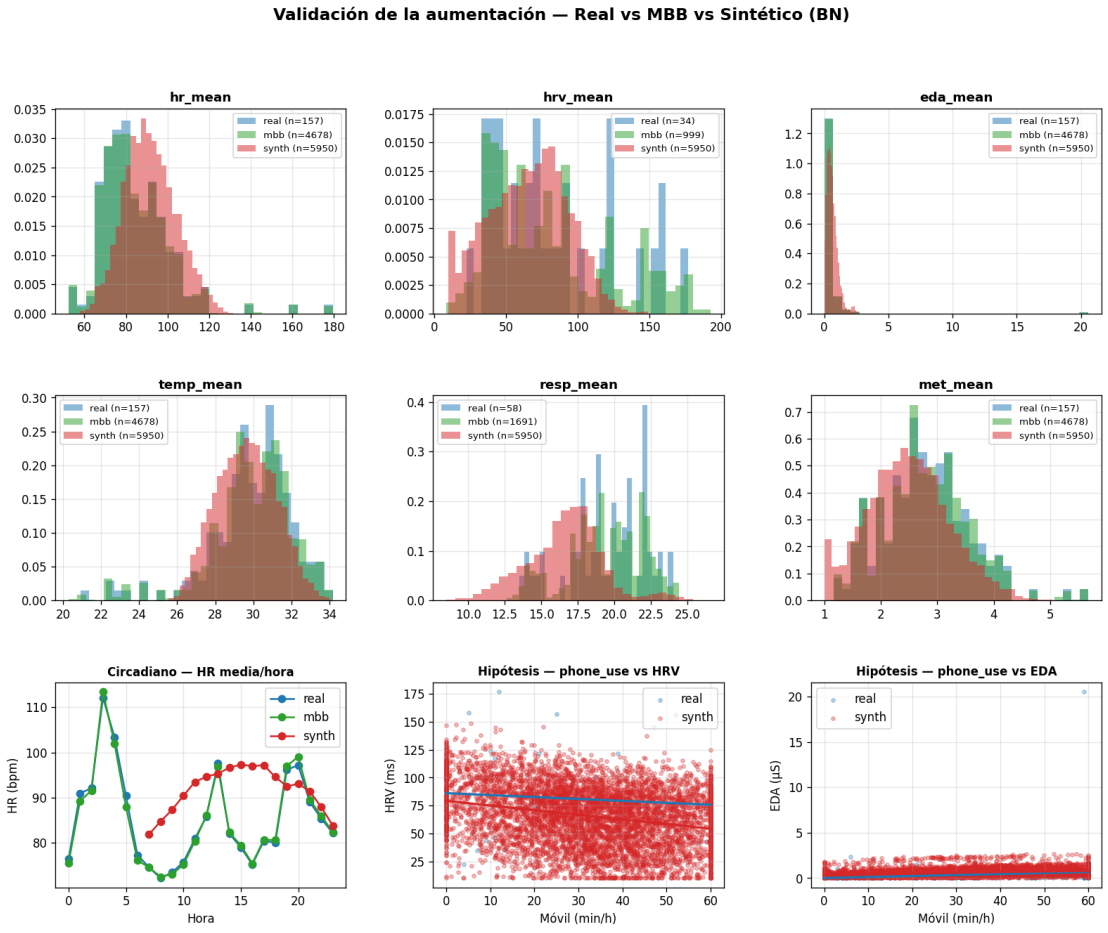


Figura 8. Validación de la aumentación: distribuciones real vs MBB vs sintético, ritmo circadiano e hipótesis inyectada.

La Figura 8 reúne nueve gráficas. Las seis primeras son los histogramas de cada biomarcador (frecuencia cardiaca, HRV, EDA, temperatura, respiración y MET), superponiendo las tres fuentes: se aprecia cómo el MBB (verde) se solapa casi perfectamente con el real (azul), mientras que el sintético (rojo) ocupa un rango similar pero algo más concentrado. La gráfica inferior izquierda muestra el ritmo circadiano de la frecuencia cardiaca (HR media por hora): el dato real (azul) y el MBB (verde) reproducen la misma curva diaria, caída nocturna y subida diurna, lo que confirma que el MBB conserva la estructura temporal real; el sintético (rojo), generado con un patrón circadiano simplificado, la sigue solo de forma aproximada y más aplanada, algo coherente con su propósito, que es aportar variabilidad entre individuos y potencia, no replicar fielmente el ritmo del sujeto real. Por último, las dos gráficas inferiores derechas ilustran la hipótesis inyectada: en los datos sintéticos (rojo) se ve la pendiente negativa de la HRV y positiva de la EDA frente al uso del móvil, mientras que en los reales (azul) la relación es mucho más débil y ruidosa, lo que adelanta uno de los hallazgos centrales del trabajo.

5.6 ANÁLISIS Y MODELADO SOBRE LA BASE AUMENTADA

Como se justificó en el apartado 5.2.4, los análisis se separan en un bloque de día, que se aborda en este apartado, y un bloque de noche, que se aborda en el 5.7. Dentro del bloque de día se presentan, en el orden en que se realizaron, la validación bayesiana del método, la relación de las señales con el bienestar y la elección de la mejor señal, y los modelos predictivo y explicativo.

5.6.1 VALIDACIÓN BAYESIANA DEL MÉTODO

Antes de interpretar ningún efecto sobre los datos reales era imprescindible comprobar que el método es capaz de detectar un efecto cuando este existe. Para ello se siguió la estrategia Train-Synthetic, Test-Real (entrenar en sintéticos, probar en reales): como en los datos sintéticos el efecto del móvil se inyectó con un valor conocido, si un modelo bayesiano lo recupera, se comprueba que el procedimiento funciona. Se analizaron los tres biomarcadores

autonómicos (HRV, frecuencia cardiaca y EDA) mediante inferencia bayesiana, que estima la distribución completa del efecto en lugar de un único número.

Conviene aclarar por qué se incluye la HRV en esta validación pese a su baja cobertura: en los datos sintéticos la HRV está completamente generada, sin huecos, de modo que sirve perfectamente para comprobar que el método recupera el efecto. Su escasa fiabilidad solo afecta a los datos reales, y precisamente por eso su distribución real aparece muy ancha e incierta (probabilidad de signo correcto en torno a 0,66). Es decir, la HRV es útil aquí para validar el método, aunque no lo sea para sostener una conclusión sobre el sujeto real.

El modelo jerárquico se especificó con priors poco informativos sobre los parámetros poblacionales: el efecto medio del móvil partió de una distribución centrada en cero con desviación uno, de modo que fueran los datos los que desplazaran esa estimación, y los parámetros de dispersión e intercepto se modelaron con distribuciones igualmente amplias. La inferencia se realizó con un muestreador moderno de tipo hamiltoniano (NUTS), empleando dos cadenas, mil quinientas muestras y mil iteraciones de calentamiento. Sobre los datos reales se ajustaron dos versiones del modelo: una con un prior no informativo, en la que solo hablan los datos reales, y otra con un prior informado por el posterior obtenido en los sujetos sintéticos, que actúa como una regularización suave aportada por el conocimiento de la cohorte virtual.

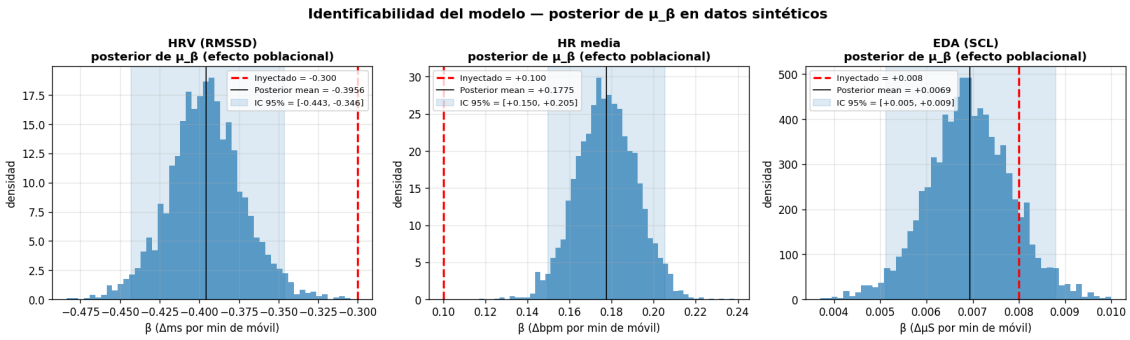


Figura 9. Distribuciones a posteriori del efecto del móvil en los datos sintéticos, con el valor inyectado (línea roja).

Recuperación del efecto en los datos sintéticos. Cada uno de los tres paneles corresponde a un biomarcador (HRV, frecuencia cardiaca y EDA). El eje horizontal es el valor del efecto

del móvil, es decir, cuánto cambia ese biomarcador por cada minuto adicional de móvil; el eje vertical es la densidad de probabilidad. El histograma azul es la distribución a posteriori del efecto medio poblacional que estima el modelo; la línea negra vertical marca su media; la banda azul claro es el intervalo de credibilidad del 95 %; y la línea roja discontinua señala el valor que se inyectó al generar los datos. La validación consiste en ver si lo estimado (azul) cae sobre la verdad (rojo). El resultado es satisfactorio: en los tres biomarcadores el modelo recupera el signo correcto (HRV negativa, frecuencia cardiaca y EDA positivas) y la media estimada queda muy cerca del valor inyectado; en la EDA, el intervalo del 95 % incluso lo contiene. La ligera desviación en HRV y HR se debe al ruido del proceso generativo.

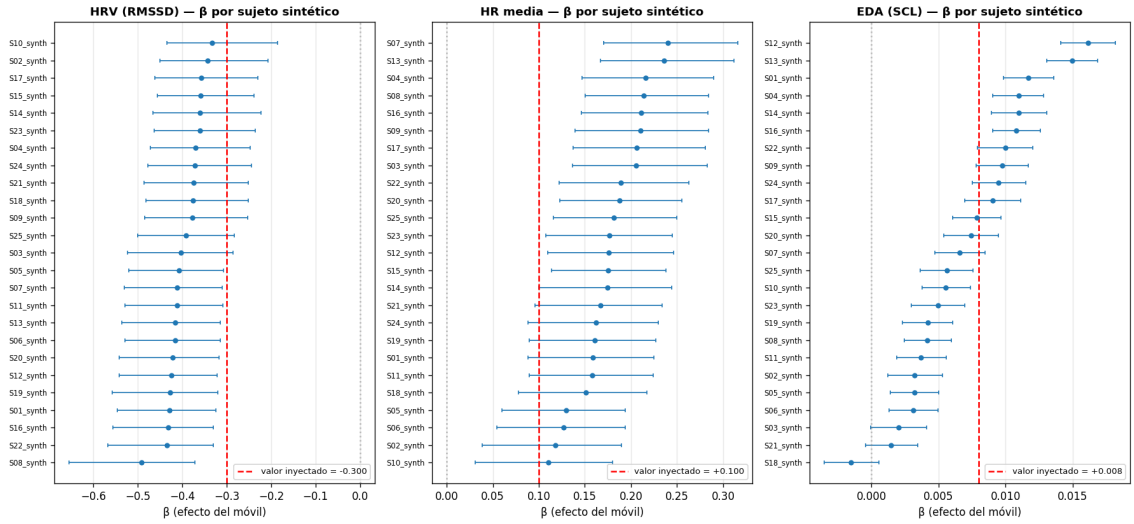


Figura 10. Efecto del móvil estimado para cada uno de los 25 sujetos sintéticos, con su intervalo de credibilidad.

Efecto sujeto a sujeto. Esta figura es un diagrama de bosque (forest plot) que desglosa el efecto en los 25 sujetos virtuales. Cada fila es un sujeto; el punto es el efecto del móvil estimado para él y la línea horizontal su intervalo de credibilidad del 95 %; la línea roja discontinua es el valor inyectado. Lo relevante es que la práctica totalidad de los intervalos rodean o cruzan la línea roja, lo que demuestra que el efecto es identificable de forma consistente entre individuos, y no producto de unos pocos casos extremos.

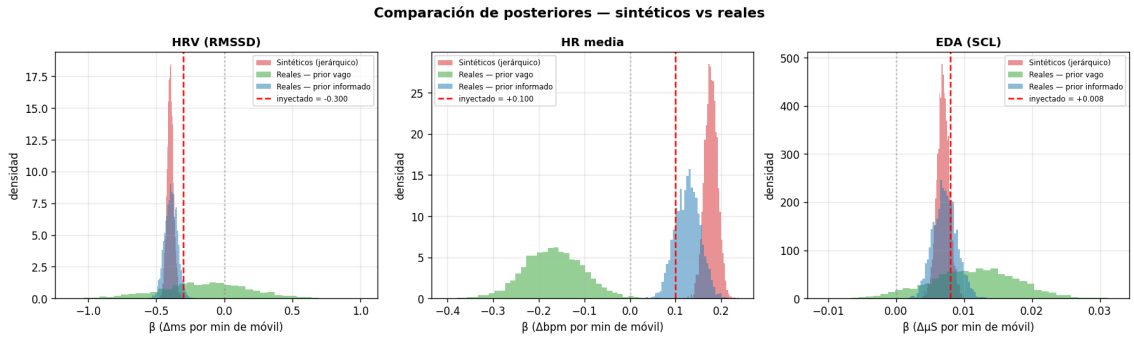


Figura 11. Comparación del efecto del móvil estimado en datos sintéticos frente a datos reales.

Sintéticos frente a reales (la figura más reveladora). Compara, para cada biomarcador, tres distribuciones del efecto del móvil: en rojo, la estimada en los sujetos sintéticos; en verde, la del sujeto real con un prior no informativo (solo hablan los datos reales); y en azul, la del sujeto real con un prior informado por la cohorte sintética. La línea roja discontinua es el valor inyectado y la línea gris punteada marca el cero, es decir, la ausencia de efecto. Lo que hay que observar es dónde se sitúa cada distribución respecto al cero y al valor inyectado:

EDA: la distribución real (verde) está claramente a la derecha del cero, confirmando el signo positivo esperado con alta probabilidad (≈ 0,96): el dato real apoya la hipótesis.

HRV: la distribución real es muy ancha y cruza el cero (probabilidad de signo correcto ≈ 0,66): apunta en la dirección correcta pero con enorme incertidumbre, reflejo de su baja cobertura.

Frecuencia cardiaca: la distribución real (verde) cae en valores negativos, de signo contrario al inyectado. No es un fallo del método, sino la huella del factor de confusión de la actividad física: los días de más móvil son más sedentarios, y eso baja la frecuencia cardiaca.

En conjunto, la validación bayesiana cumple su doble función: muestra que el pipeline detecta el efecto cuando está presente (sintéticos) y, aplicado a los datos reales, revela que solo la EDA sostiene con claridad la relación esperada, mientras que la frecuencia cardiaca

está dominada por el confundidor de actividad. Esto justifica los dos pasos siguientes: identificar formalmente la mejor señal y construir un modelo que controle la actividad física.

5.6.2 QUÉ SEÑALES SE RELACIONAN CON EL BIENESTAR

Una vez validado el método, el primer análisis sobre el bloque de día fue determinar qué biomarcadores se relacionan más con el índice de bienestar, en su versión diurna calculada sobre la base aumentada. La Figura 12 lo resume en tres paneles.

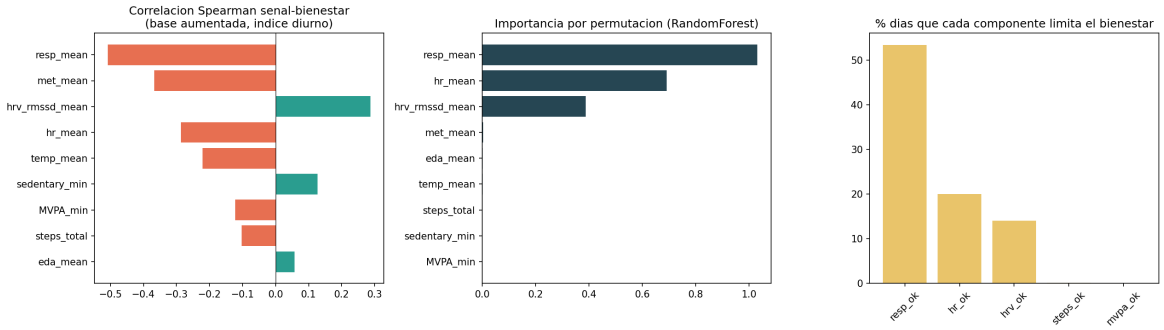


Figura 12. Relación de cada señal con el índice de bienestar: correlación (izq.), importancia en RandomForest (centro) y porcentaje de días que limita el bienestar (der.).

El panel izquierdo muestra la correlación de Spearman entre cada señal y el índice de bienestar: las barras rojas indican relación negativa y las verdes positiva. La señal que más se relaciona es la frecuencia respiratoria ($\rho \approx -0{,}51$), seguida del MET, la HRV (positiva) y la frecuencia cardiaca. El panel central muestra la importancia de cada señal según un modelo de Random Forest, es decir, cuánto empeora la predicción al eliminarla: dominan claramente la respiración, la frecuencia cardiaca y la HRV, mientras que el resto tiene una importancia menor para reconstruir el índice. El panel derecho indica el porcentaje de días en que cada componente suspende y por tanto limita el bienestar: la respiración es el cuello de botella más frecuente (≈ 53 % de los días), seguida de la HR y la HRV.

Conviene matizar la lectura de la EDA: que aquí muestre poca relación con el índice **no significa que sea poco importante**, sino que el índice de bienestar se construye a partir de las señales autonómicas (respiración, HR y HRV) y no de la EDA. La relevancia de la EDA

es de otra naturaleza, es el canal por el que se manifiesta el efecto del móvil, y se demuestra en los apartados siguientes.

La conclusión es clara: en el bloque de día, el índice de bienestar lo determinan, por construcción, las señales autonómicas (respiración, frecuencia cardiaca y HRV), mientras que la actividad física, que durante la vigilia apenas varía, casi nunca limita el índice. La relación del uso del móvil con el bienestar no se examina aquí, el móvil no es una señal fisiológica, sino en los análisis específicos de los apartados siguientes.

5.6.3 RELACIÓN MULTIVARIANTE ENTRE EL MÓVIL Y LOS BIOMARCADORES

El siguiente paso fue estudiar cómo se relaciona el uso del móvil con cada biomarcador, ya no de uno en uno sino teniendo en cuenta el conjunto. La Figura 13 muestra la matriz de correlación de todas las variables horarias.

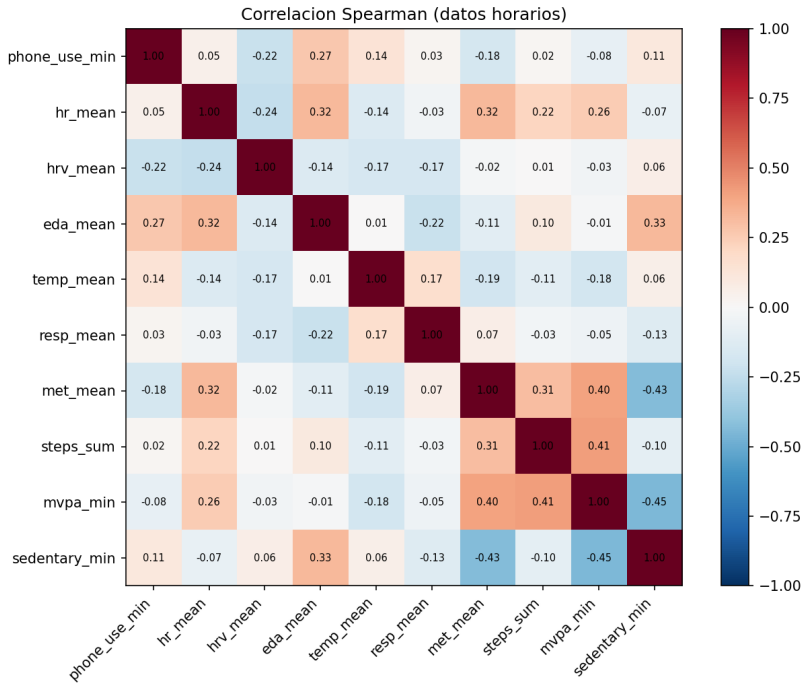


Figura 13. Matriz de correlación de Spearman entre el uso del móvil y los biomarcadores (datos horarios).

Cada celda es la correlación de Spearman entre dos variables; el color va del azul (correlación negativa) al rojo (positiva), con el valor numérico dentro. Fijándonos en la

primera fila (uso del móvil), se observa que el móvil correlaciona positivamente con la EDA (+0,27, la más alta), de forma negativa con la HRV (−0,22) y el MET (−0,18), y débilmente con el resto. Es decir, las horas de más móvil tienden a coincidir con más activación electrodérmica y algo menos de variabilidad cardiaca y de gasto metabólico.

Ahora bien, una correlación simple puede estar contaminada por la actividad física. Por eso se ajustó, para cada biomarcador, el efecto del móvil controlando la actividad, y se comparó entre las tres fuentes de datos. La Figura 14 recoge ese efecto.

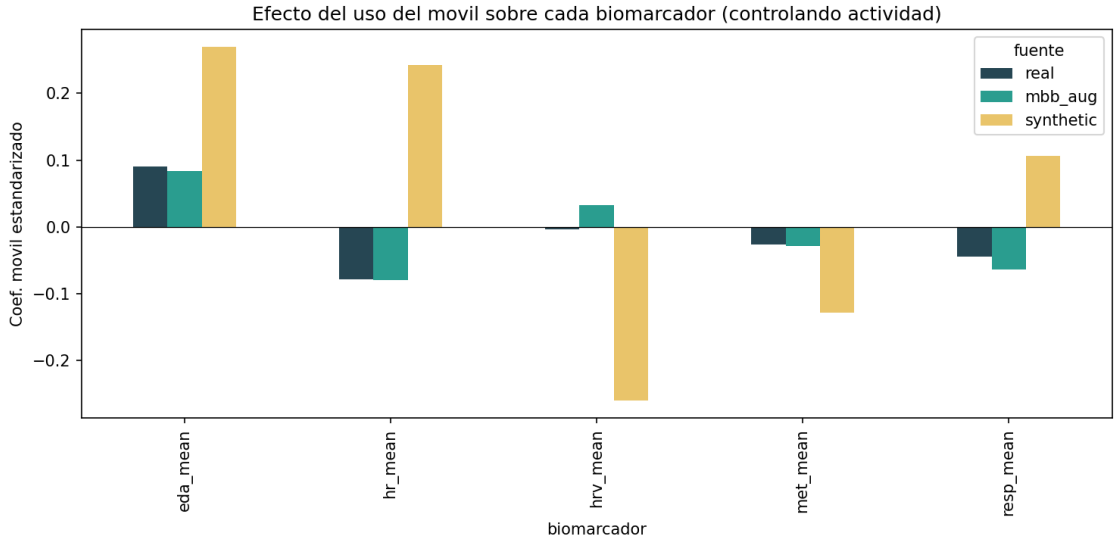


Figura 14. Efecto del uso del móvil sobre cada biomarcador, controlando la actividad, en datos reales, MBB y sintéticos.

Cada grupo de barras es un biomarcador, y los tres colores son las fuentes de datos (real, MBB y sintético); el eje vertical es el coeficiente estandarizado del móvil (positivo significa que el móvil lo sube; negativo, que lo baja), una vez descontada la actividad física. La lectura es la clave de todo el trabajo: la EDA es el único biomarcador en el que las tres fuentes coinciden en signo positivo, en los datos reales, en el MBB y en el sintético, confirmando que el móvil se asocia de forma robusta a mayor activación. En cambio, en la frecuencia cardiaca y la respiración el dato real y el sintético tienen signos opuestos: el sintético muestra el efecto inyectado, pero el real apunta al contrario por el confundidor de actividad ya comentado.

Este confundidor puede cuantificarse de forma directa en la frecuencia cardiaca. En los datos reales, el uso del móvil se asocia a una menor actividad física (r = −0,17) y la actividad física, a su vez, eleva con fuerza la frecuencia cardiaca (r = +0,64); la combinación de ambas relaciones produce una correlación negativa bruta entre móvil y frecuencia cardiaca (r = −0,20) sin que exista un efecto directo. Al aislar la actividad mediante una correlación parcial, esa asociación se reduce de −0,20 a −0,12 (Figura 15), en torno a un 40 %, acercándose a cero. Esto confirma que buena parte del efecto aparente del móvil sobre la frecuencia cardiaca es obra de la actividad física, y muestra que el procedimiento es capaz de detectar y descontar este tipo de factores de confusión, requisito imprescindible para escalar el análisis a más individuos.

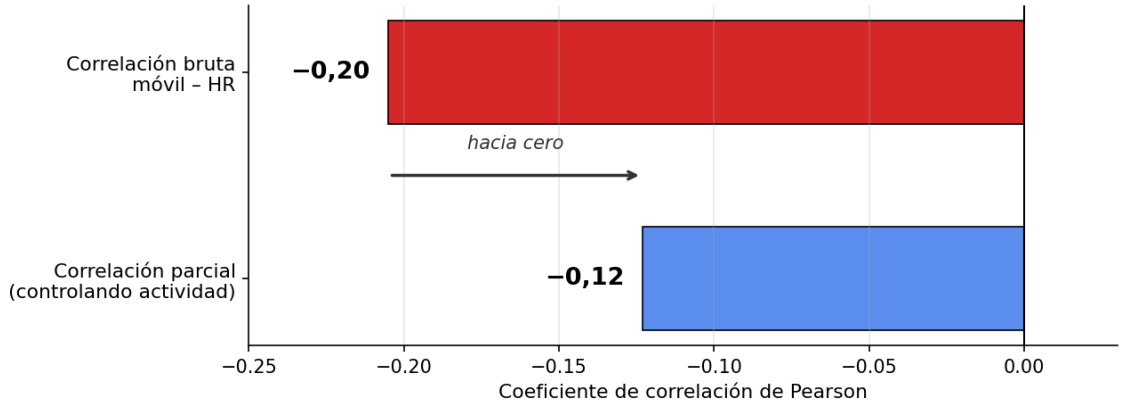


Figura 15. Asociación móvil–frecuencia cardiaca antes y después de controlar la actividad física.

5.6.4 SELECCIÓN DE LA MEJOR SEÑAL

Los análisis anteriores señalan a la EDA como la candidata más fiable, pero esa decisión se tomó de forma cuantitativa y no a ojo. Se puntuó cada biomarcador combinando cinco criterios: la fuerza de su relación con el móvil, la consistencia del signo entre datos reales y sintéticos, su robustez frente al confundidor de actividad, su cobertura y su relevancia para el bienestar. La Figura 16 muestra el resultado.

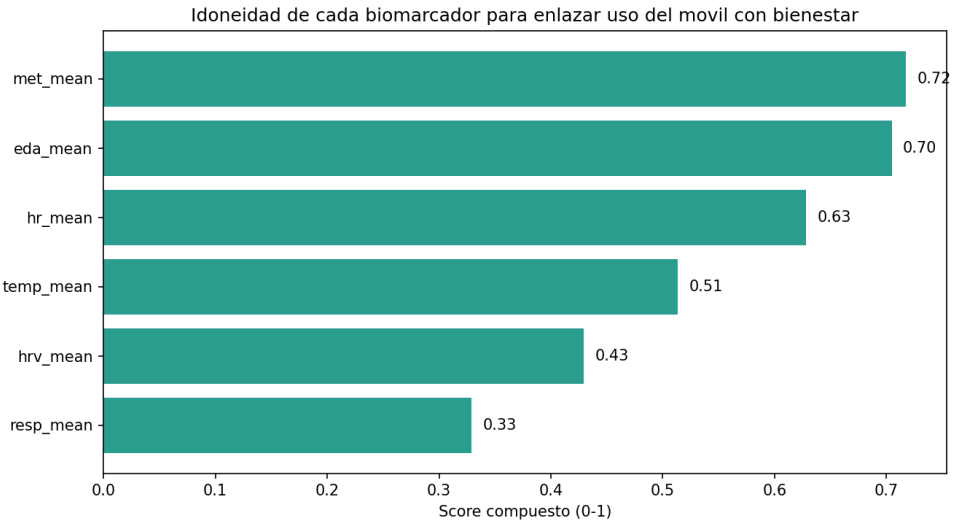


Figura 16. Puntuación compuesta de cada biomarcador como canal para enlazar el uso del móvil con el bienestar.

Cada barra es la puntuación compuesta (de 0 a 1) de un biomarcador como canal para enlazar el uso del móvil con el bienestar. El MET (0,72) y la EDA (0,70) encabezan la lista, seguidos de la frecuencia cardiaca (0,63). Sin embargo, el MET es esencialmente actividad física, es decir, mide el propio factor de confusión, no un efecto de bienestar, por lo que se descarta como canal. La EDA es, por tanto, la mejor señal: es el marcador directo de activación (arousal), mantiene el signo esperado tanto en datos reales como sintéticos, resiste el confundidor de actividad y tiene cobertura alta. La frecuencia cardiaca, pese a estar bien cubierta, queda invalidada por el confundidor; y la HRV, ideal en teoría, se penaliza por su baja cobertura.

En resumen, este bloque establece que, durante el día, el rastro del móvil sobre la fisiología circula por la activación electrodérmica (EDA), mientras que su relación con el índice de bienestar global es muy débil. Queda por comprobar si ese efecto sobre la activación llega a traducirse en un cambio medible del bienestar, lo que se aborda con los modelos del apartado siguiente.

5.6.5 MODELOS CONSIDERADOS Y CRITERIO DE SELECCIÓN

Para el modelado se consideraron varias familias de modelos, que conviene definir antes de aplicarlos:

Regresión lineal regularizada (Ridge): la opción más simple; ajusta una recta penalizando los coeficientes grandes para evitar el sobreajuste. Es interpretable, pero solo capta relaciones lineales.

Random Forest: un conjunto (ensemble) de muchos árboles de decisión, entrenados cada uno sobre subconjuntos aleatorios de datos y variables; sus predicciones se promedian. Captura relaciones no lineales y de umbral, es robusto, requiere poco ajuste y ofrece la importancia de cada variable.

Gradient Boosting: también un conjunto de árboles, pero construidos de forma secuencial, corrigiendo cada uno los errores del anterior. Suele ser muy preciso, aunque más sensible al ajuste de hiperparámetros.

Modelo de efectos mixtos: una regresión que incorpora un término aleatorio por sujeto, separando la variación entre individuos de la variación dentro de cada individuo; es el estándar para datos de panel, con varias observaciones por sujeto.

Inferencia bayesiana: en lugar de un único valor, estima la distribución completa del efecto con su incertidumbre; resulta idónea para validar la recuperación de un efecto conocido y para trabajar con pocos datos.

El criterio de selección fue doble. Por un lado, la capacidad predictiva, medida mediante validación cruzada por sujeto. Por otro, y más importante, la adecuación a la pregunta del trabajo: distinguir entre un modelo que prediga bien el índice (predictivo) y un modelo que mida el efecto del móvil de forma interpretable (explicativo). Como se verá, esta distinción resultó decisiva: el Random Forest es el mejor modelo predictivo, pero el modelo final del trabajo es el de efectos mixtos, por ser el único que responde a la pregunta sin caer en

circularidad. La justificación cuantitativa de ambas elecciones se desarrolla a continuación con los resultados.

5.6.6 MODELOS PREDICTIVOS DEL BIENESTAR

El primer enfoque de modelado fue el más natural: ¿se puede predecir el índice de bienestar? Para responderlo se compararon cuatro modelos, una línea base que predice siempre la media, una regresión regularizada (Ridge), un Random Forest y un Gradient Boosting, sobre dos conjuntos de predictores distintos: DRIVERS, que incluye todas las señales fisiológicas, y CONDUCTUAL, que incluye solo el uso del móvil y el contexto (hora, fin de semana). La evaluación se hizo con validación cruzada por sujeto (GroupKFold), que entrena con unos sujetos y prueba en otros distintos, de modo que mide la capacidad real de generalización y no el sobreajuste.

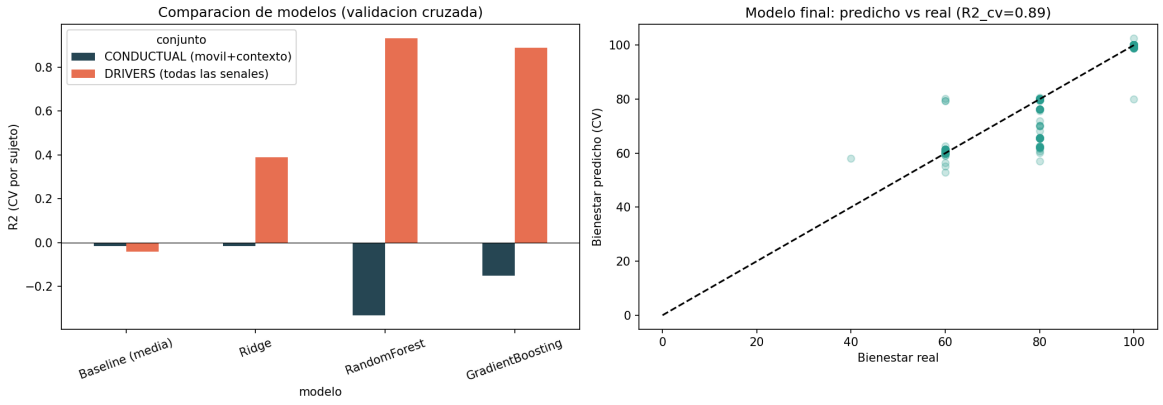


Figura 17. Comparación de modelos por validación cruzada (izq.) y ajuste del mejor modelo, predicho frente a real (der.).

El panel izquierdo compara el R^2 (validación cruzada por sujeto) de cada modelo; las barras rojas son el conjunto DRIVERS y las azules el CONDUCTUAL. Los resultados son muy elocuentes. Con todas las señales (rojo), el Random Forest alcanza un R^2 de 0,93 y el Gradient Boosting de 0,89, muy por encima de la regresión lineal (0,39) y de la línea base ($\approx$ 0). Pero con solo el móvil y el contexto (azul), todos los modelos fracasan, con R^2 negativos, es decir, peores que predecir la media. El panel derecho muestra el ajuste del

mejor modelo, predicho frente a real, con los puntos alineados razonablemente con la diagonal ($R^2 = 0,89$).

La elección del modelo dentro de este enfoque también tiene su razón. El índice de bienestar es un constructo no lineal y basado en umbrales, un tipo de relación que los modelos de árboles, Random Forest y Gradient Boosting, capturan de forma natural, mientras que la regresión lineal (Ridge) no puede, lo que explica su R^2 mucho más bajo. Entre los dos modelos de árboles, el Random Forest resultó algo más estable en la validación cruzada por sujeto ($R^2 = 0,93$ frente a 0,89), por lo que se adoptó como modelo predictivo de referencia; además, es robusto, requiere poco ajuste de hiperparámetros y proporciona de forma directa la importancia de cada variable.

A primera vista, un R^2 de 0,93 parecería un éxito rotundo. Sin embargo, este modelo no sirve como modelo central del trabajo, por dos razones de fondo que la Figura 18 hace evidentes.

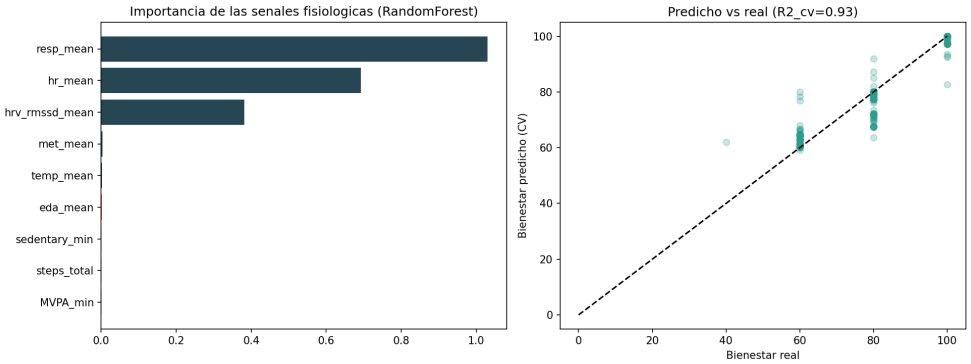


Figura 18. Modelo predictivo: importancia de las señales fisiológicas (izq.) y ajuste predicho frente a real (der.).

El panel izquierdo muestra la importancia por permutación de cada señal, es decir, cuánto empeora la predicción del índice al desordenar al azar esa variable: la reconstrucción del índice la dominan claramente la respiración, la frecuencia cardiaca y la HRV. El panel derecho confirma el buen ajuste del modelo, con los valores predichos alineados con los reales ($R^2 = 0,93$). Conviene, no obstante, interpretar esta alta precisión con cautela, por la circularidad que se explica a continuación.

Las dos razones quedan así demostradas. La primera es la **circularidad**: el índice de bienestar se construye a partir de las propias señales fisiológicas, de modo que predecirlo a partir de ellas es casi una tautología; el alto R^2 no descubre nada nuevo, solo confirma que el índice depende de sus ingredientes. La segunda es que **el uso del móvil no añade capacidad de predecir el índice**: una prueba de ablación confirma que incluirlo en el modelo mejora el R^2 en apenas seis diezmilésimas. Esto no contradice los hallazgos anteriores, el móvil sí deja un rastro en la EDA, sino que indica que ese rastro no basta para mover el índice global de bienestar. En consecuencia, este modelo predictivo se conserva como prueba de que el pipeline funciona, pero no responde a la pregunta del TFG, que no es ¿puedo predecir el bienestar? sino ¿cómo afecta el móvil al bienestar?

5.6.7 EL MODELO FINAL: UN MODELO EXPLICATIVO

La conclusión del apartado anterior obliga a cambiar de paradigma: de un modelo predictivo (una caja negra que estima el bienestar a partir de muchas variables) a un modelo explicativo (que sitúa el uso del móvil como variable independiente y mide su efecto sobre el bienestar). Se eligió un modelo de efectos mixtos, y la elección está cuidadosamente justificada por cuatro razones.

Responde directamente a la pregunta: estima un coeficiente para el uso del móvil, con su signo, su magnitud y su intervalo de confianza, que es exactamente lo que se busca.

Respeta la estructura de los datos: la base aumentada es un panel con 56 sujetos (el sujeto real, sus 30 réplicas por Moving Block Bootstrap y los 25 sujetos virtuales generados por la red bayesiana) y varias observaciones por cada uno; un modelo de regresión ordinario trataría todas las observaciones como independientes e inflaría la significación, mientras que los efectos mixtos incorporan un intercepto aleatorio por sujeto que separa correctamente la variación entre individuos de la variación dentro de cada individuo.

Permite descomponer el efecto: distingue uno total y otro ajustado por la actividad física, imprescindible para aislar el confundidor identificado en todos los análisis previos.

Evita la circularidad: no usa como predictores las señales que componen el índice.

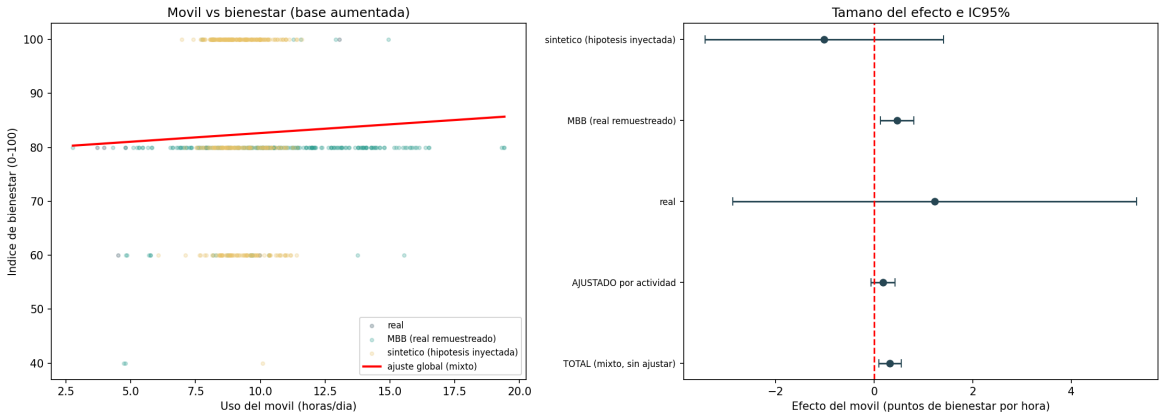


Figura 19. Modelo explicativo: uso del móvil frente al bienestar (izq.) y tamaño del efecto del móvil con su IC95% en distintas configuraciones (der.).

El panel izquierdo representa el uso del móvil (en horas al día) frente al índice de bienestar, con cada fuente de datos en un color y la recta del ajuste mixto global en rojo: la pendiente es ligeramente positiva pero casi plana. El panel derecho es un diagrama de efectos que resume el coeficiente del móvil (en puntos de bienestar por hora de uso) y su intervalo de confianza del 95 % en distintas configuraciones; la línea roja vertical marca el cero. La lectura es la conclusión central del trabajo: el efecto total del móvil es de +0,32 puntos por hora (pequeño pero significativo), pero al ajustar por la actividad física cae a +0,18 y deja de ser significativo, ya que su intervalo cruza el cero. Es decir, casi la mitad de ese efecto aparente se debe en realidad al confundidor de actividad, no al móvil. El desglose por fuente confirma la incoherencia esperada: el dato real y el MBB dan un efecto ligeramente positivo, mientras que el sintético, con la hipótesis inyectada, da uno negativo.

Un último dato del modelo es que el coeficiente de correlación intraclase (ICC) es de 0,80; es decir, en la cohorte aumentada la mayor parte de la variación del bienestar se da entre sujetos y solo una fracción dentro de cada uno. Como esa variabilidad entre individuos procede de los sujetos sintéticos, este valor debe interpretarse como una propiedad del conjunto simulado y no como una conclusión sobre diferencias individuales reales (véase el apartado de Limitaciones).

La conclusión del bloque de día es, por tanto, que en este sujeto el uso del móvil tiene un efecto pequeño, positivo y no robusto sobre el bienestar diurno, que se diluye al controlar la actividad física. El único rastro fisiológico claro del móvil es el aumento de la activación electrodérmica (EDA), pero esa activación no llega a traducirse en un cambio medible del bienestar global.

5.7 ANÁLISIS DEL SUEÑO (BLOQUE NOCHE)

El bloque de día concluyó que el rastro diurno del móvil se limita a la activación (EDA), sin llegar al bienestar global. Queda la otra vía por la que el móvil podría afectar al bienestar: la nocturna. La hipótesis, bien documentada en la literatura, es una cadena: el uso del móvil a última hora empeora el sueño, y un peor sueño empeora el bienestar del día siguiente. Como la base aumentada es solo de vigilia, este bloque se analiza sobre los datos reales, distinguiendo dos aspectos del sueño: su cantidad y su calidad.

5.7.1 CANTIDAD DE SUEÑO: LA CADENA MÓVIL, SUEÑO Y BIENESTAR

Para cada noche se calcularon tres variables: el uso del móvil en la tarde-noche del día, los minutos de sueño de esa noche y el índice de bienestar del día siguiente. La Figura 20 representa los tres eslabones de la cadena.

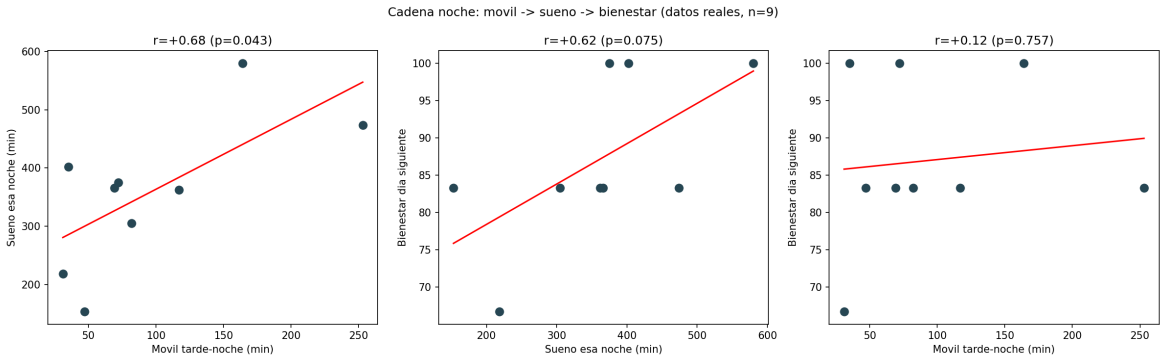


Figura 20. Cadena nocturna: móvil tarde-noche → sueño esa noche → bienestar del día siguiente (datos reales, n=9).

Cada panel es una relación de la cadena, sobre las nueve noches con datos completos. El panel izquierdo relaciona el móvil de la tarde-noche con el sueño de esa noche (r = +0,68, p

= 0,043); el central, el sueño con el bienestar del día siguiente (r = +0,62, p = 0,075); y el derecho, el efecto directo del móvil tarde-noche sobre el bienestar del día siguiente (r = +0,12, p = 0,757). La recta roja es el ajuste lineal de cada relación.

La lectura es a la vez clara y contraria a la hipótesis. El eslabón central sí se cumple con fuerza: dormir más se asocia a mejor bienestar al día siguiente (r ≈ 0,6), coherente con todo lo visto. Pero el primer eslabón contradice lo esperado: el uso del móvil a última hora no reduce el sueño, sino que va acompañado de más sueño (r ≈ +0,68). Y el efecto directo del móvil sobre el bienestar del día siguiente es nulo (r ≈ 0,12). La explicación más plausible es un confundidor de estilo de vida: las noches tranquilas en casa concentran a la vez más uso del móvil y más horas de cama, típicamente los fines de semana. Para dar robustez a estas relaciones, limitadas por solo nueve noches, se aplicó el mismo remuestreo MBB, que estrechó los intervalos y confirmó el mismo patrón (móvil-sueño ≈ +0,73; sueño-bienestar ≈ +0,56; móvil-bienestar ≈ +0,11), descartando que se debiera al azar de unos pocos días.

5.7.2 CALIDAD DEL SUEÑO

Más allá de la cantidad, se analizó si el móvil deteriora la calidad del sueño, medida con cinco indicadores: duración, eficiencia, número de despertares (fragmentación), porcentaje de sueño profundo, y la frecuencia cardiaca y la HRV nocturnas como marcadores de recuperación. Se cruzaron con dos formas de uso del móvil: el total del día y, sobre todo, el uso a horas tardías, que es la prueba directa de la hipótesis de las pantallas antes de dormir. La Figura 21 muestra las correlaciones.

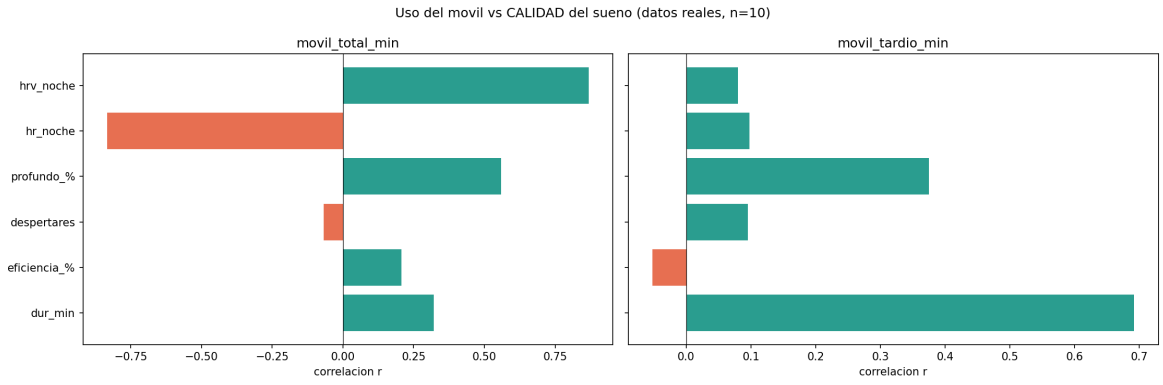


Figura 21. Uso del móvil (total y a horas tardías) frente a la calidad del sueño (datos reales, n=10).

Cada barra es la correlación entre una métrica de calidad del sueño y el uso del móvil; el panel izquierdo corresponde al móvil total del día y el derecho al móvil a horas tardías. El resultado es inequívoco para la pregunta clave: el móvil a horas tardías no deteriora ninguna métrica de calidad, no aumenta los despertares, no reduce la eficiencia ni el sueño profundo, ni empeora la frecuencia cardiaca o la HRV nocturnas; lo único que aparece es una correlación positiva con la duración. En el móvil total del día sí se ven correlaciones fuertes con la frecuencia cardiaca nocturna (negativa) y la HRV nocturna (positiva), pero ambas apuntan, de nuevo, a mejor recuperación, lo que confirma el confundidor de estilo de vida: los días tranquilos y sedentarios concentran más móvil y, esas noches, el cuerpo está más recuperado. El móvil no causa esa mejor recuperación; ambos son consecuencia de un día relajado.

En conjunto, el bloque de noche refuerza la conclusión del trabajo: ni la cantidad ni el horario del uso del móvil deterioran el sueño en este sujeto. El sueño es, efectivamente, un determinante fuerte del bienestar, pero el móvil no es la causa de un peor sueño, y las asociaciones aparentes, incluso las que parecen beneficiosas, son fruto de factores de estilo de vida y no de un efecto del teléfono. Conviene recordar la principal limitación: estos análisis se basan en nueve o diez noches de un solo sujeto, por lo que son exploratorios y su valor reside en la coherencia con el resto de bloques, no en su potencia estadística.

5.8 USO DEL MÓVIL POR CATEGORÍAS

Todos los análisis anteriores tratan el uso del móvil como un único bloque de minutos. Pero no es lo mismo una hora de redes sociales que una de productividad o de juegos. El último análisis del capítulo aprovecha el desglose por categorías, disponible solo en los datos reales, para explorar si el tipo de uso importa. Se cruzaron las cuatro categorías principales (redes sociales, entretenimiento, productividad y juegos) con cuatro indicadores: el bienestar continuo, el bienestar por umbrales, la EDA (activación) y los minutos de sueño. La Figura 22 resume las correlaciones.

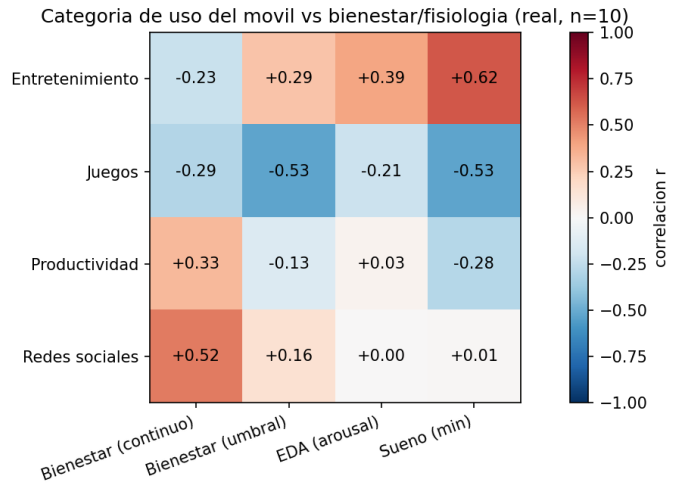


Figura 22. Correlación entre cada categoría de uso del móvil y el bienestar y la fisiología (datos reales, n=10).

Es un mapa de calor: cada fila es una categoría de uso y cada columna un indicador; el color y el número indican la correlación, del azul (negativa) al rojo (positiva). La lectura, por filas, deja varios patrones. Las redes sociales, que son, con diferencia, el uso mayoritario, se relacionan positivamente con el bienestar (+0,52 en el índice continuo) y de forma neutra con la EDA y el sueño: el grueso del uso del móvil no aparece como perjudicial. La productividad es prácticamente neutra. El entretenimiento va asociado a más activación (EDA +0,39) y a más sueño (+0,62). Y los juegos son la única categoría que apunta de forma consistente a peor: menor bienestar (−0,53 en el índice por umbrales) y menos sueño (−0,53), aunque con un uso muy reducido.

El matiz honesto es obligado: con solo diez días y cuatro categorías por cuatro indicadores, estas correlaciones son exploratorias y no concluyentes, ninguna sobreviviría a una corrección por comparaciones múltiples, por lo que deben leerse como generadoras de hipótesis, no como resultados firmes. Aun así, la señal cualitativa es interesante y coherente con la conclusión global: el uso dominante (redes sociales) no se asocia a peor bienestar, y solo los juegos, marginales en tiempo, insinúan un efecto negativo que merecería estudiarse con más datos.

Con este análisis se cierra el capítulo, que ha recorrido todo el sistema desarrollado: desde la extracción y preparación de los datos, pasando por la definición del bienestar, el análisis

exploratorio y la aumentación, hasta el modelado del bloque de día, el del bloque de noche y, finalmente, el desglose por categorías de uso.

Capítulo 6. ANÁLISIS DE RESULTADOS

Este capítulo recoge y destaca los resultados más relevantes obtenidos en el Capítulo 5, organizados por bloques y referidos a las figuras correspondientes. Más allá de enumerar los hallazgos, se interpretan y se contrastan con la literatura, para ofrecer una lectura clara de qué se encontró en cada parte y qué significa.

6.1 VALIDEZ DE LOS DATOS Y DEL MÉTODO

Antes de los resultados de fondo conviene fijar que el trabajo descansa sobre datos y un método validado. La cobertura efectiva del wearable fue alta (86,6 % de media), con la salvedad de la HRV y la respiración, de cobertura baja durante la vigilia y, por tanto, tratadas como secundarias. La aumentación se validó estadísticamente: el remuestreo por bloques (MBB) resultó indistinguible del dato real en los tests de Kolmogórov–Smirnov, y el bloque sintético mantuvo rangos fisiológicamente plausibles.

El paso de validación más importante fue, sin embargo, el bayesiano. Al recuperar correctamente el efecto inyectado en los datos sintéticos (estrategia Train-Synthetic, Test-Real), se demostró que el pipeline es sensible: detecta el efecto del móvil cuando este existe. Esta comprobación es la que permite interpretar la ausencia de efecto en los datos reales como información, no hay un efecto apreciable, y no como una simple falta de potencia del método.

6.2 EL EFECTO DEL MÓVIL DE DÍA: LA VÍA DEL AROUSAL

En el bloque de día, el resultado central es que el único rastro fisiológico consistente del móvil es el aumento de la activación electrodérmica (EDA): es la única señal cuyo efecto mantiene el signo esperado tanto en los datos reales como en los sintéticos (Figura 14), lo que la convirtió en la mejor señal del estudio (Figura 16). Este hallazgo es coherente con el papel

de la EDA como marcador directo de activación simpática y con su robustez frente al movimiento, que la hace más fiable que la HRV en vida libre.

La frecuencia cardiaca, en cambio, ilustra un fenómeno instructivo. La regresión simple sugería una relación negativa fuerte (a más móvil, menor HR), pero el análisis multivariante la reveló como un artefacto del factor de confusión de la actividad física: los días de más móvil son más sedentarios, y el sedentarismo, por sí solo, baja la frecuencia cardiaca. Es un ejemplo de cómo una correlación llamativa puede desaparecer, o incluso invertirse, al controlar la variable adecuada (Figura 15).

En este sujeto, ese arousal no parece traducirse en un cambio del bienestar global. El modelo explicativo final cifra el efecto del móvil en +0,32 puntos de bienestar por hora de uso, pequeño y, llamativamente, de signo positivo, que además se reduce a +0,18 y deja de ser significativo al controlar la actividad física (Figura 19).

6.3 EL EFECTO DEL MÓVIL DE NOCHE: EL SUEÑO

En el bloque de noche, el resultado, en este sujeto, también va en contra de la hipótesis habitual. El sueño sí muestra una asociación fuerte con el bienestar, dormir más se asocia a mejor bienestar al día siguiente ($r \approx 0{,}6$), pero el uso del móvil no se asocia a un peor sueño: ni la cantidad, el uso a última hora se asocia incluso a más sueño (Figura 20), ni la calidad, el uso tardío no empeora los despertares, la eficiencia, el sueño profundo ni la recuperación (Figura 21).

Este resultado merece un matiz interpretativo. La literatura sí describe una asociación entre el uso nocturno del móvil y un peor sueño, atribuida a la luz azul y al arousal; pero esa evidencia es mayoritariamente transversal y autoinformada. En este sujeto, con medidas objetivas, no se reproduce ese deterioro, y las correlaciones aparentes, incluso las que parecen beneficiosas, como una mejor recuperación nocturna en los días de más móvil, se explican por un confundidor de estilo de vida: los días tranquilos en casa concentran a la vez más móvil y un mejor descanso.

6.4 EL TIPO DE USO DEL MÓVIL

El análisis por categorías (Figura 22), de carácter exploratorio, sugiere que no todas las horas de móvil son iguales: las redes sociales, el uso mayoritario, no se asocian a peor bienestar, mientras que los juegos, marginales en tiempo, son la única categoría que apunta de forma consistente a un efecto negativo. Esta distinción conecta con la idea, cada vez más extendida en la literatura, de que importa más cómo y en qué se usa el móvil que el tiempo total de pantalla. Aun así, con tan pocos días es una hipótesis a confirmar, no un resultado firme.

6.5 DISCUSIÓN: COMPARACIÓN CON LA LITERATURA

Los resultados de este trabajo encajan, de forma notable, con la literatura científica más rigurosa. El hallazgo de un efecto pequeño y no robusto coincide con el estudio de referencia de Orben y Przybylski (2019) [11], que sobre más de 350.000 personas estimó que la tecnología digital explica como mucho el 0,4 % de la variación del bienestar, y que el signo del efecto depende fuertemente de las decisiones de análisis. Que aquí el efecto sea minúsculo y se diluya al controlar la actividad va en la misma dirección.

El trabajo aporta, además, dos elementos que la literatura mayoritaria no tiene. Por un lado, medidas objetivas: frente al uso autoinformado, que correlaciona mal con el real [4], aquí el uso se obtiene del propio dispositivo y se cruza con fisiología continua. Por otro, el control explícito del confundidor de actividad física, que resultó ser la clave para no confundir un efecto del sedentarismo con un efecto del móvil. La principal divergencia con parte de la literatura del sueño se explica precisamente por esto: muchos estudios no separan el móvil de los hábitos de vida que lo acompañan.

En conjunto, la contribución no es un veredicto llamativo, sino una observación, a nivel individual, de que en este sujeto el efecto directo del móvil sobre el bienestar es pequeño y está muy mediado por el contexto.

6.6 SÍNTESIS DE RESULTADOS

La Tabla 6 resume los hallazgos cuantitativos principales.

Análisis	**Resultado clave**	**Lectura**
Regresión simple (HR ~ móvil)	$r = -0{,}79$; $R^2 = 0{,}62$	Relación negativa, confundida por actividad
Móvil ↔ biomarcadores	EDA: único signo consistente	El móvil eleva el arousal (EDA)
Mejor señal	EDA (score 0,70)	Canal fisiológico del móvil
Modelo predictivo del bienestar	$R^2 = 0{,}93$	Pipeline válido pero circular; el móvil no aporta
Modelo explicativo (móvil → bienestar)	+0,32 pts/h → +0,18 (n.s.) ajustado	Efecto pequeño que se diluye con la actividad
Variación entre personas (ICC)	0,80	En la cohorte aumentada, la mayor parte de la variación es entre sujetos (propiedad del conjunto simulado)
Sueño (cantidad)	móvil→sueño r=+0,68; sueño→bienestar r=+0,62	El móvil no reduce el sueño; el sueño sí importa
Sueño (calidad)	móvil tardío sin efecto	El móvil no deteriora la calidad del sueño
Categorías	redes neutro; juegos r=−0,53 (expl.)	El tipo de uso podría importar

Tabla 6. Resumen de los resultados cuantitativos principales.

En conjunto, los resultados convergen desde varios ángulos: en este sujeto, el uso del móvil no muestra indicios claros del efecto perjudicial esperado sobre el bienestar. Su único rastro fisiológico claro es un leve aumento de la activación (EDA) durante el día, que no parece trasladarse al bienestar global ni deteriorar el sueño; y en este caso, el sueño aparece como el factor más asociado al bienestar, por encima del uso del móvil.

Capítulo 7. CONCLUSIONES Y TRABAJOS FUTUROS

7.1 CONCLUSIONES

El trabajo se propuso diseñar y validar una metodología para medir, con datos objetivos de un wearable, cómo afecta el uso del móvil al bienestar, y cuantificar esa relación de forma honesta. Los seis objetivos planteados se cumplieron: se integró una base unificada de wearable y móvil; se definió un índice de bienestar reproducible en dos versiones; se aumentó la base de datos más de sesenta veces con validación estadística; se identificó cuantitativamente la EDA como mejor señal; se construyó un modelo explicativo que aísla el efecto del móvil del de la actividad física; y se reportó ese efecto con su incertidumbre.

La conclusión principal, acotada a este sujeto, es que el uso del móvil no muestra indicios claros del efecto perjudicial sobre el bienestar que la intuición y buena parte del discurso social dan por hecho. El análisis apunta en esa dirección desde varios frentes. La regresión simple sugería una relación, pero el análisis multivariante la desmontó como un artefacto de la actividad física: los días de más móvil son más sedentarios, y es el sedentarismo, no el teléfono, lo que mueve la fisiología. El único rastro genuino del móvil es un leve aumento de la activación electrodérmica (EDA) durante el día, coherente con la hipótesis de arousal; pero ese aumento de activación no se propaga al bienestar global: el modelo explicativo cifra el efecto en apenas +0,32 puntos por hora, positivo, no negativo, y lo disuelve hasta la no significación en cuanto se controla la actividad. De noche, en la misma línea: ni la cantidad ni el horario del uso del móvil se asocian a un peor sueño, en contra de la creencia extendida sobre las pantallas antes de dormir.

Dos hallazgos transversales refuerzan la lectura. Primero, que en este sujeto el sueño aparece como el factor más asociado al bienestar, muy por encima del uso del móvil. Y segundo, que la metodología es sensible: la validación bayesiana demostró que el pipeline detecta el efecto del móvil cuando este existe, en los datos sintéticos, de modo que su ausencia en los datos reales es información, no falta de potencia.

En suma, el trabajo entrega una conclusión honesta y bien fundamentada que matiza el relato simplista de más móvil, peor bienestar. Su valor no está en un veredicto llamativo, sino en haber medido con rigor, separado el efecto real de sus confundidores y reconocido la incertidumbre, una postura que además coincide con la literatura científica más reciente y cuidadosa, que también encuentra efectos pequeños, mixtos y muy dependientes del contexto.

7.2 APORTACIONES DEL TRABAJO

La aportación principal es metodológica: un procedimiento completo y reproducible para estudiar la relación móvil–bienestar a partir de un único sujeto monitorizado intensivamente, que combina captura multimodal, un índice de bienestar objetivo, aumentación de datos que preserva la estructura temporal, y un modelado que distingue el efecto del móvil de su confundidor principal. Son aportaciones destacables la reconstrucción reproducible del índice de bienestar, la validación del método mediante datos sintéticos con efecto conocido, y la estructuración del análisis en bloques de día y noche según el mecanismo fisiológico.

7.3 LIMITACIONES

El trabajo tiene limitaciones que conviene declarar. La principal es que se basa en un único sujeto y diez días útiles (once registrados), lo que limita la generalización y la potencia estadística. La base de datos sintética incorpora la hipótesis por diseño, por lo que valida el método pero no constituye una prueba independiente de la hipótesis; en la misma línea, el reparto de la variación del bienestar entre sujetos (ICC = 0,80) refleja una propiedad de esa cohorte sintética y no una medida de diferencias individuales reales. La HRV y la frecuencia respiratoria tuvieron baja cobertura y se trataron como secundarias. Y los análisis por categorías de uso y del sueño son exploratorios, basados en muy pocos días. A ello se añade que el uso del móvil se registró a resolución horaria, a partir de los totales de Tiempo de Uso, y no con la marca temporal de cada episodio de uso, lo que impide un análisis de respuesta aguda minuto a minuto.

7.4 LÍNEAS FUTURAS

El propio diseño del trabajo marca el camino para extenderlo, y las limitaciones se convierten así en una hoja de ruta concreta.

Ampliar a varios sujetos (N > 1). Es la extensión más inmediata y necesaria: replicar el estudio con una cohorte real de varios participantes y más semanas daría validez externa, permitiría estudiar la variabilidad entre individuos con datos reales, no simulados, y reduciría el peso de la variabilidad entre sujetos que en este diseño procede de datos sintéticos (ICC = 0,80).

Explotar la resolución por minuto. Los datos del wearable están a un minuto y apenas se han aprovechado a esa escala. Un análisis de la respuesta aguda, alinear los episodios de uso del móvil y medir la EDA y la frecuencia cardiaca en los minutos circundantes, mediría el efecto en la escala temporal en la que el arousal debería manifestarse, y de forma inmune al confundidor de estilo de vida diario. Para ello sería necesario registrar también el uso del móvil con marca temporal de minuto, por ejemplo mediante una aplicación dedicada que anote cada episodio de uso, ya que la resolución horaria actual no lo permite; de hecho, una prueba preliminar a nivel horario no reveló un efecto agudo más allá del ritmo circadiano.

Formalizar la mediación causal. Convertir la cadena observada, móvil → activación (EDA) → bienestar, en un modelo de mediación causal explícito sobre datos reales permitiría cuantificar qué parte del pequeño efecto pasa por la vía del arousal.

Validar el índice de bienestar. El índice se construyó a partir de la fisiología; contrastarlo con autoinformes o cuestionarios de bienestar cerraría el círculo entre la medida objetiva y la percepción subjetiva del usuario.

Profundizar en el tipo de uso. La señal exploratoria de que los juegos podrían asociarse a peor bienestar y sueño, frente a unas redes sociales neutras, merece un estudio dedicado con suficiente volumen por categoría.

Hacia la intervención y la personalización. A más largo plazo, la metodología habilita estudios de intervención, medir el bienestar al reducir deliberadamente el uso del móvil, y sistemas de retroalimentación personalizada que, en lugar de demonizar el móvil, ayuden a cada usuario a entender qué hábitos concretos, sueño, actividad, tipo de uso, mueven realmente su bienestar.

Capítulo 8. BIBLIOGRAFÍA

1. [1] American Heart Association (2021). *Target Heart Rates Chart*. https://www.heart.org
2. [2] Boucsein, W. (2012). *Electrodermal Activity* (2.ª ed.). Springer.
3. [3] Breiman, L. (2001). Random Forests. *Machine Learning, 45*(1), 5–32.
4. [4] Ellis, D. A., Davidson, B. I., Shaw, H., y Geyer, K. (2019). Do smartphone usage scales predict behavior? *International Journal of Human-Computer Studies, 130*, 86–92.
5. [5] Empatica Inc. (2023). *EmbracePlus: Digital Biomarkers Documentation*.
6. [6] Iwana, B. K., y Uchida, S. (2021). An empirical survey of data augmentation for time series classification with neural networks. *PLOS ONE, 16*(7), e0254841.
7. [7] Kumar, M., Katoch, O. R., Kumar, N., y Sehgal, S. (2025). Exploring the link between smartphone use and sleep quality: A systematic review. *Sleep Research, 2*(1), 42–56.
8. [8] McCulloch, W. S., y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics, 5*, 115–133.
9. [9] Menghini, L., Gianfranchi, E., Cellini, N., Patron, E., Tagliabue, M., y Sarlo, M. (2019). Stressing the accuracy: Wrist-worn wearable sensor validation over different conditions. *Psychophysiology, 56*(11), e13441.
10. [10] Onnela, J.-P., y Rauch, S. L. (2016). Harnessing smartphone-based digital phenotyping to enhance behavioral and mental health. *Neuropsychopharmacology, 41*(7), 1691–1696.
11. [11] Orben, A., y Przybylski, A. K. (2019). The association between adolescent well-being and digital technology use. *Nature Human Behaviour, 3*(2), 173–182.
12. [12] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., VanderPlas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., y Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research, 12*, 2825–2830.
13. [13] Pérez, J., Castro, M., Awad, E., y López, G. (2024). Generation of probabilistic synthetic data for serious games: A case study on cyberbullying. *Knowledge-Based Systems, 286*, 111440.
14. [14] Politis, D. N., y Romano, J. P. (1994). The stationary bootstrap. *Journal of the American Statistical Association, 89*(428), 1303–1313.

15. [15] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review, 65*(6), 386–408.
16. [16] Salvatier, J., Wiecki, T. V., y Fonnesbeck, C. (2016). Probabilistic programming in Python using PyMC3. *PeerJ Computer Science, 2*, e55.
17. [17] Sano, A., Taylor, S., McHill, A. W., Phillips, A. J. K., Barger, L. K., Klerman, E., y Picard, R. (2018). Identifying objective physiological markers and modifiable behaviors for self-reported stress and mental health status using wearable sensors and mobile phones. *Journal of Medical Internet Research, 20*(6), e210.
18. [18] Seabold, S., y Perktold, J. (2010). Statsmodels: Econometric and statistical modeling with Python. *Proceedings of the 9th Python in Science Conference*, 92–96.
19. [19] Shaffer, F., y Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in Public Health, 5*, 258.

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS

Los Objetivos de Desarrollo Sostenible (ODS) son las 17 metas aprobadas por las Naciones Unidas en la Agenda 2030 para orientar el desarrollo social, económico y ambiental. Este trabajo, centrado en la medición objetiva del bienestar y en la innovación metodológica con dispositivos vestibles e inteligencia artificial, se alinea principalmente con tres de ellos.

ODS 3 – SALUD Y BIENESTAR

Es el objetivo con el que el trabajo se relaciona de forma más directa. El proyecto desarrolla una metodología para cuantificar el bienestar de una persona a partir de biomarcadores fisiológicos objetivos, en lugar de depender únicamente de cuestionarios subjetivos. Contribuye así a la meta 3.4, orientada a promover la salud mental y el bienestar, al aportar herramientas para entender de forma rigurosa qué hábitos, sueño, actividad física, uso del móvil, influyen realmente en el bienestar diario. Además, al desmontar con datos la creencia simplista de que el uso del móvil es necesariamente perjudicial, el trabajo fomenta un enfoque de la salud digital basado en evidencia y no en alarmismo, evitando recomendaciones de salud infundadas.

ODS 9 – INDUSTRIA, INNOVACIÓN E INFRAESTRUCTURA

El trabajo es, ante todo, una aportación metodológica e innovadora. Integra tecnologías emergentes, wearables de grado de investigación, interpretación de datos mediante inteligencia artificial con visión y técnicas avanzadas de aumentación y modelado estadístico, en un pipeline reproducible. En línea con la meta 9.5, sobre el fomento de la investigación y la capacidad tecnológica, el proyecto propone una infraestructura de análisis replicable y honesta que puede reutilizarse y escalarse en estudios posteriores de salud

digital, contribuyendo a la generación de conocimiento y a la innovación en el ámbito de la monitorización fisiológica.

ODS 4 – EDUCACIÓN DE CALIDAD

De forma complementaria, el trabajo contribuye a la alfabetización científica y digital. Al mostrar de manera transparente cómo se distingue un efecto real de un factor de confusión, y al comunicar los resultados con su incertidumbre, el proyecto promueve un pensamiento crítico y basado en datos sobre el papel de la tecnología en nuestras vidas, en consonancia con la meta 4.7 sobre la adquisición de conocimientos para el desarrollo sostenible y los estilos de vida saludables.

ANEXO II

….NOTA: Esta parte hace referencia a posibles Anexos opcionales de la memoria que se quieran añadir (código fuente, hojas de características, planos, etc.). NO se refiere a los documentos Anexos que se indican en la normativa (Anexo A, Anexo B, etc.)