



Facultad de Ciencias Económicas y Empresariales  
ICADE

# Evaluación de la conciliación vida-trabajo con la introducción de IA generativa en el espacio laboral de la UE

Autor: Luis Málaga Santaella

Directora: Dra. María Jesús Belizón Cebada

## **Abstract**

This Final Degree Project analyses the association between generative artificial intelligence (AI) use at work and five dimensions of work–life balance (WLB) among workers in the European Union. In a context of rapid digitalisation and an evolving European regulatory framework (AI Act, right to disconnect), understanding how generative AI reshapes the boundaries between professional and personal life is particularly relevant for organisations, workers, and public-policy stakeholders.

The study uses individual-level microdata from the European Working Conditions Survey (EWCS) 2024/25 (N = 25,138 workers across EU-27). OLS stepwise models with HC3 robust standard errors are estimated for five WLB dimensions: global work–life fit (D1), time-based work–family interference (D2), work in free time (D3), strain-based cognitive interference (D4), and schedule predictability as an organisational facilitator (D5). Dependent variables are inverted with a dimension-specific criterion: in D1 and D5 a positive coefficient indicates better WLB; in D2, D3, and D4 a positive coefficient indicates greater interference or spill-over (worse WLB). Models follow a cumulative M1–M3 structure with sociodemographic and job controls, occupation (ISCO-1) and sector (NACE) dummies, country fixed effects, and interaction terms between AI use and three organisational moderators (telework, job autonomy, and work intensity) in M3.

Results show that generative AI use is not associated with any significant WLB improvement across the five dimensions. On the contrary, three dimensions show significant negative associations: AI users work significantly more in their free time (D3), experience greater time-based work–family interference (D2), and report higher cognitive tension outside working hours (D4). The intensification channel dominates the efficiency channel: work intensity amplifies temporal spill-over, job autonomy amplifies cognitive strain in D2 and D4, and telework partially mitigates temporal spill-over in D3 but not cognitive tension. The study concludes with recommendations for organisations (workload management, digital disconnection policies, boundary-management training) and for European public policy (AI Act, disconnection directive, European Pillar of Social Rights).

## **Keywords**

Work–life balance, Generative AI, Work intensification, Digital disconnection, Telework, European Union labor market, European Working Conditions Survey (EWCS), Job Demands–Resources model.

## **Resumen**

Este Trabajo de Fin de Grado analiza la asociación entre el uso de inteligencia artificial generativa (IA generativa) en el trabajo y cinco dimensiones de conciliación vida–trabajo (WLB) entre los trabajadores de la Unión Europea. En un contexto de rápida digitalización y de desarrollo del marco regulatorio europeo (AI Act, derecho a la desconexión), entender cómo la IA generativa reconfigura los límites entre vida laboral y personal resulta especialmente relevante para organizaciones, trabajadores y responsables de política pública.

El estudio utiliza microdatos de la European Working Conditions Survey (EWCS) 2024/25 (N = 25.138 trabajadores de la UE-27). Se estiman modelos OLS stepwise con errores estándar robustos HC3 para cinco dimensiones de WLB: encaje global trabajo–vida (D1), interferencia temporal trabajo–familia (D2), trabajo en tiempo libre (D3), interferencia por tensión cognitiva (D4) y predicibilidad del horario como facilitador organizativo (D5). Las variables dependientes se invierten siguiendo un criterio específico por dimensión: en D1 y D5 un coeficiente positivo indica mejor WLB; en D2, D3 y D4 un coeficiente positivo indica mayor interferencia o desbordamiento (peor WLB). Los modelos siguen una estructura acumulativa M1–M3 con controles sociodemográficos y laborales, dummies de ocupación (ISCO-1) y sector (NACE), efectos fijos de país y, en M3, términos de interacción entre el uso de IA y tres moderadores organizativos (teletrabajo, autonomía e intensidad laboral).

Los resultados muestran que el uso de IA generativa no se asocia con ninguna mejora significativa de la conciliación en ninguna de las cinco dimensiones. Por el contrario, tres dimensiones presentan asociaciones negativas significativas: los usuarios de IA trabajan significativamente más en su tiempo libre (D3), experimentan mayor interferencia temporal entre el trabajo y la familia (D2) y reportan mayor tensión cognitiva fuera del horario laboral (D4). El canal de intensificación domina sobre el canal de eficiencia: la intensidad laboral amplifica el desbordamiento temporal, la autonomía amplifica la tensión cognitiva en D2 y D4, y el teletrabajo mitiga parcialmente el desbordamiento temporal en D3 pero no la tensión cognitiva. El trabajo concluye con recomendaciones para organizaciones (gestión de carga, políticas de desconexión digital, formación en gestión de límites) y para la política pública europea (AI Act, Directiva de desconexión, Pilar Europeo de Derechos Sociales).

## **Palabras clave**

Conciliación vida-trabajo, IA generativa, Intensificación del trabajo, Desconexión digital, Teletrabajo, Mercado laboral de la Unión Europea, Encuesta Europea sobre Condiciones de Trabajo (EWCS), Modelo Demandas–Recursos.

## Índice

1.	<i>Introducción</i> .....	8
1.1.	Presentación y justificación del tema .....	8
1.2.	Objetivos de la investigación.....	9
1.3.	Estructura del trabajo.....	10
2.	<i>Marco Teórico</i> .....	11
2.1	Conciliación vida-trabajo (WLB): definición, dimensiones y relevancia.....	11
2.2	Digitalización, flexibilidad y teletrabajo: oportunidades y riesgos.....	15
2.3.	IA en el trabajo (incluida IA generativa): bienestar, control y gestión algorítmica.....	16
2.4.	Marco integrador: recursos, demandas y apoyos para explicar la relación IA - WLB.....	18
2.5.	El “doble efecto” tecnológico: mejora vs. estrés por reemplazo e intensificación .....	18
2.6.	Moderadores organizativos: autonomía, intensidad y teletrabajo del efecto de la IA.....	20
3.	<i>Metodología de Investigación</i> .....	22
3.1.	Descripción de la base de datos: European Working Conditions Survey 2024/2025 .....	22
3.2.	Clasificación de los países de la muestra.....	23
3.3.	Diseño del estudio y enfoque analítico.....	24
3.4.	Análisis descriptivo .....	26
3.5.	Análisis de correlaciones .....	30
3.6.	Test de multicolinealidad (VIF).....	31
3.7.	Variables del modelo y especificación .....	32
3.8.	Pruebas de robustez y limitaciones .....	33
4.	<i>Resultados</i> .....	34
4.1.	Presentación general de los resultados .....	34
4.2.	D1: Encaje global vida–trabajo .....	35
4.3.	D2: Interferencia trabajo–familia basada en tiempo .....	36
4.4.	D3: Trabajo fuera del horario laboral.....	37
4.5.	D4: Interferencia trabajo–familia basada en tensión.....	38
4.6.	D5: Facilitadores organizativos – Predicibilidad del horario .....	39
4.7.	Efectos moderadores: modelos de interacción .....	40
4.8.	Síntesis: contraste de hipótesis .....	41
5.	<i>Discusión</i> .....	43
6.	<i>Recomendaciones</i> .....	51
6.1.	Recomendaciones para organizaciones y responsables de RRHH .....	51
6.2.	Recomendaciones para responsables de política pública.....	53
7.	<i>Referencias</i> .....	57
8.	<i>Declaration of the use of AI</i> .....	60
9.	<i>Apéndice A. Código de análisis en Python</i> .....	61

## **Figuras**

Figura 3.1. Distribución del uso de IA generativa por país, sector y ocupación.....	28
Figura 3.2. Conciliación vida-trabajo: usuarios vs no usuarios de IA generativa.....	28
Figura 3.3. WLB global, adopción de IA generativa y peso de pymes por clúster.....	29
Figura 3.4. Distribución de las dimensiones WLB (D1–D5) por grupo de uso de IA.....	30
Figura 3.5. Matrices de correlación de Spearman.....	31
Figura 4.1. Coeficientes de IA generativa y términos de interacción.....	41

## Tablas

Tabla 2.1 Síntesis de hipótesis del estudio.....	21
Tabla 3.1. Clasificación de países UE-27 por cluster institucional.....	24
Tabla 3.2. Estadísticos descriptivos de las variables del modelo.....	27
Tabla 3.3. Test de multicolinealidad — Factor de Inflación de la Varianza (VIF) 32	
Tabla 4.1. Resultados de los modelos OLS Stepwise.....	34
Tabla 4.2. Regresión OLS — Encaje global WLB (D1).....	36
Tabla 4.3. Regresión OLS — Interferencia temporal (D2).....	37
Tabla 4.4. Regresión OLS — Trabajo fuera de horario (D3).....	38
Tabla 4.5. Regresión OLS — Interferencia por tensión (D4).....	39
Tabla 4.6. Regresión OLS — Predicibilidad del horario (D5).....	40
Tabla 4.7. Efectos de interacción IA × moderadores.....	40
Tabla 4.8. Síntesis: contraste de hipótesis.....	42

## Lista de abreviaturas

AI Act	Reglamento (UE) 2024/1689 sobre inteligencia artificial
COR	Conservation of Resources — Teoría de Conservación de Recursos
D1–D5	Dimensiones de conciliación vida-trabajo (variables dependientes del estudio)
EU	European Union (forma inglesa, usada en el Abstract)
EWCS	European Working Conditions Survey — Encuesta Europea sobre Condiciones de Trabajo
FSE+	Fondo Social Europeo Plus
GPAI	General Purpose AI — IA de propósito general
HC3	Heteroskedasticity-Consistent estimator — estimador robusto de errores estándar, orden 3
IA	Inteligencia Artificial
ISCO	International Standard Classification of Occupations — Clasificación Internacional Uniforme de Ocupaciones
JD–R	Job Demands–Resources model — Modelo Demandas–Recursos
M1–	Especificaciones del modelo OLS (stepwise): Modelo 1 (controles), Modelo 2
M3	(+IA+moderadores), Modelo 3 (+interacciones)
NACE	Nomenclatura estadística de actividades económicas de la Comunidad Europea
ODS 8	Objetivo de Desarrollo Sostenible 8 — Trabajo decente y crecimiento económico (Agenda 2030, ONU)
OLS	Ordinary Least Squares — Mínimos Cuadrados Ordinarios
Pyme	Pequeña y mediana empresa ( $\leq 249$ empleados)
UE	Unión Europea
UE-27	Los 27 Estados miembros de la Unión Europea
VIF	Variance Inflation Factor — Factor de Inflación de la Varianza
WLB	Work-Life Balance — Conciliación vida-trabajo

## 1. Introducción

### 1.1. Presentación y justificación del tema

La adopción de inteligencia artificial (IA) en el trabajo y, en particular, de IA generativa (asistentes conversacionales, herramientas de redacción o apoyo al análisis), se ha acelerado en la UE y ya no se limita a proyectos piloto. Este cambio ocurre además en un momento regulatorio y organizativo clave: la Ley Europea de IA (AI Act) entró en vigor el 1 de agosto de 2024 y su calendario de aplicación introduce obligaciones progresivas, incluyendo disposiciones específicas para modelos de propósito general (GPAI) desde agosto de 2025 (European Commission, 2024). En paralelo, el debate sobre el derecho a la desconexión se ha intensificado: el Parlamento Europeo pidió una directiva en 2021 y la Comisión lanzó en abril de 2024 una consulta a interlocutores sociales sobre teletrabajo justo y desconexión (European Parliament, 2021). En este contexto, entender cómo la IA reconfigura el tiempo de trabajo, los ritmos y la capacidad real de desconectar es especialmente relevante para empresas, trabajadores y políticas públicas.

El interés del tema se apoya en una tensión central. Por un lado, la IA generativa puede actuar como recurso: automatiza tareas repetitivas, reduce tiempos de preparación (búsqueda, síntesis, redacción) y facilita flexibilidad, lo que podría mejorar la conciliación (Lee, 2024; Vyas, 2022). Por otro lado, puede funcionar como demanda: elevar expectativas de velocidad, aumentar la disponibilidad fuera de horario y reforzar formas de gestión algorítmica (monitorización, ritmo fijado por sistemas), incrementando la intensidad del trabajo y erosionando límites vida-trabajo. Esta dualidad está respaldada por la literatura reciente: se documentan efectos simultáneos de mejora (por mejores condiciones o capacidades) y de estrés por reemplazo (inseguridad y presión), con impactos heterogéneos según características del puesto y la organización (Chen & Li, 2024). Además, revisiones sobre IA y bienestar subrayan que los efectos dependen del contexto (cultura, gestión, diseño de roles) y que la integración de IA puede vincularse a estrés, inseguridad o pérdida de autonomía si no se implementa con salvaguardas (Lee, 2024). La evidencia sobre teletrabajo y digitalización también advierte que la flexibilidad puede venir acompañada de difuminación de fronteras y dinámicas de conectividad constante, con riesgos para la conciliación (Vyas, 2022).

El problema es que, pese al aumento del uso de IA en el trabajo, todavía hay poca evidencia comparada y representativa que permita cuantificar su relación con la conciliación a escala europea y separarla de otros factores de organización del trabajo como la intensidad, la

autonomía o el teletrabajo (Fan et al., 2021; Lee, 2024). En este sentido, la European Working Conditions Survey es una fuente idónea porque permite analizar condiciones laborales y calidad de vida laboral con comparabilidad internacional (Eurofound, 2025). La edición 2024/25 recoge por primera vez un módulo específico sobre IA generativa en el trabajo y documenta que el 11,2% de los trabajadores de la UE-27 declara utilizar estas herramientas, con variación sustancial entre países (desde el 2,7% en Rumanía hasta el 21,8% en Dinamarca), sectores y ocupaciones (Eurofound, 2025).

Por tanto, este TFG se justifica por su contribución práctica y académica: (i) aportar una fotografía comparable del grado de adopción de IA generativa en la UE y su distribución por país, ocupación y sector; y (ii) estimar, con modelos OLS stepwise con errores robustos HC3 y controles exhaustivos, la asociación entre esa adopción y cinco dimensiones de conciliación, analizando bajo qué condiciones organizativas la IA se vincula con intensificación y dificultad de desconexión. Este enfoque conecta con los marcos JD-R y COR, que explican cómo demandas y recursos organizativos influyen en el bienestar y por qué los efectos varían según el contexto (Bakker & Demerouti, 2007; Hobfoll, 1989).

## **1.2. Objetivos de la investigación**

El objetivo general de la presente investigación es evaluar la asociación entre el uso de IA generativa en el trabajo y la conciliación vida-trabajo (WLB) de los trabajadores de la Unión Europea, analizando tanto el efecto directo como las condiciones organizativas que lo moderan, mediante microdatos de la European Working Conditions Survey (EWCS) 2024/25. Los objetivos específicos son:

1. Documentar el grado de adopción de IA generativa en la UE-27 y su distribución por país (cluster institucional), ocupación (ISCO), sector (NACE), tamaño de empresa y modalidad de trabajo (teletrabajo/presencial).
2. Construir y operacionalizar cinco dimensiones de WLB a partir de ítems de la EWCS (D1: encaje global trabajo-vida; D2: interferencia temporal trabajo-familia; D3: trabajo en tiempo libre; D4: interferencia por tensión cognitiva; D5: predicibilidad horaria). Las escalas se invierten siguiendo un criterio específico por dimensión: en D1 y D5, un valor mayor indica mejor WLB (mejor encaje global y mayor predicibilidad respectivamente); en D2, D3 y D4, un valor mayor indica más interferencia o desbordamiento (peor WLB).

3. Estimar modelos OLS stepwise con errores estándar robustos HC3 para evaluar la asociación entre el uso de IA generativa y cada dimensión de WLB, controlando por características sociodemográficas y laborales, efectos fijos de país, ocupación y sector.
4. Analizar el papel moderador de la autonomía laboral, la intensidad del trabajo y el teletrabajo mediante términos de interacción, identificando en qué condiciones la IA generativa agrava o mitiga el impacto sobre la conciliación.
5. Derivar recomendaciones prácticas para organizaciones y para la política pública europea orientadas a una adopción de IA generativa que no deteriore la conciliación de los trabajadores de la UE.

### **1.3. Estructura del trabajo**

En primer lugar, el trabajo desarrolla una revisión de la literatura sobre la relación entre la digitalización del trabajo, la IA generativa y la conciliación vida–trabajo. Esta revisión sintetiza los principales mecanismos, ganancias de eficiencia y flexibilidad frente a intensificación y difuminación de límites, y construye el marco teórico integrador a partir del modelo JD–R, el marco COR y la literatura sobre apoyo organizativo a la WLB (Fan et al., 2021; Haar & Harris, 2025). A partir de esta síntesis se formulan las cinco hipótesis (H1–H5) y se definen las variables clave: cinco dimensiones WLB como variables dependientes, el uso de IA generativa como variable explicativa principal y tres moderadores organizativos (autonomía, intensidad laboral, teletrabajo).

En segundo lugar, se presenta la fuente de datos y el diseño empírico. Se describen los microdatos de la EWCS 2024/25 (Eurofound), su diseño muestral y representatividad para la UE-27 (N total = 28.621; muestra de modelo N = 25.138 con información completa). Se detalla la clasificación de países en cinco clusters institucionales (Nórdico, Continental, Liberal, Mediterráneo y Europa del Este), la operacionalización e inversión de las cinco dimensiones WLB, y el conjunto de 51 variables de control en los modelos base.

En tercer lugar, se realiza el análisis cuantitativo en dos etapas. Primero, estadísticos descriptivos, correlaciones de Spearman y test de multicolinealidad (VIF) documentan la distribución de la adopción de IA y las relaciones bivariadas. Segundo, se estiman modelos OLS stepwise con errores robustos HC3: el Modelo 1 incluye solo controles; el Modelo 2 añade la variable de IA generativa y los tres moderadores; el Modelo 3 incorpora los términos de interacción (M3a–M3c y M3 completo). Los resultados se presentan por dimensión (Secciones

4.2–4.6), con síntesis de los efectos moderadores (Sección 4.7) y contraste de hipótesis H1–H5 (Sección 4.8).

En cuarto lugar, la Sección 5 desarrolla la discusión interpretando cada hipótesis a la luz de la literatura, el papel de los moderadores organizativos, la heterogeneidad institucional entre clusters de países y las limitaciones metodológicas (diseño transversal, variable binaria de IA, auto-declaración). La Sección 6 formula doce recomendaciones prácticas, seis para organizaciones y seis para responsables de política pública europea, derivadas directamente de los hallazgos, con fundamento empírico, actor destinatario y horizonte temporal para cada una. El trabajo cierra con la lista de referencias bibliográficas.

## **2. Marco Teórico**

### **2.1 Conciliación vida-trabajo (WLB): definición, dimensiones y relevancia**

La conciliación vida-trabajo (work–life balance, WLB) se entiende como el grado en que una persona percibe que puede gestionar adecuadamente múltiples roles (trabajo, vida personal, familia y otras responsabilidades), manteniendo un equilibrio funcional que le permita rendir y sostener su bienestar en ambos dominios. Esta definición enfatiza que la conciliación es, ante todo, una evaluación subjetiva sobre la capacidad de gestionar demandas y recursos entre ámbitos, más que un simple resultado “objetivo” de horas trabajadas (Haar, 2013; Fan et al., 2021). Por ello, dos personas con condiciones laborales similares pueden reportar niveles muy distintos de WLB si difieren en su percepción de control, carga, límites o capacidad de recuperación.

Una aportación clave para delimitar el concepto es situarlo frente a constructos cercanos: el conflicto trabajo-vida (o trabajo-familia) y el enriquecimiento trabajo-vida. El conflicto describe interferencias negativas entre roles; la conciliación, en cambio, capta una valoración global de armonía/ajuste entre dominios y puede reflejar beneficios derivados de gestionar roles con éxito (Haar, 2013; Haar & Harris, 2025). En este sentido, la conciliación no equivale simplemente a “ausencia de conflicto”, sino a una vivencia de compatibilidad entre la esfera laboral y la no laboral.

La literatura contemporánea subraya que la conciliación debe analizarse como un fenómeno multicausal y condicionado por el entorno: no depende solo de decisiones individuales, sino también de apoyos reales y percibidos, y de cómo se implementan en la práctica. Fan et al.

(2021) conceptualizan el “work–life balance support” como recursos externos (tangibles o intangibles), percibidos o realmente existentes, que permiten expandir o asignar mejor los recursos personales para cumplir demandas laborales y no laborales. Además, sitúan dichos apoyos en un marco multinivel, diferenciando recursos en el micro-nivel (familia/red personal), en el nivel del lugar de trabajo (supervisión, equipo, organización) y en el nivel societal (políticas públicas, infraestructuras y normas culturales) (Fan et al., 2021). Para el caso europeo, este enfoque resulta especialmente útil, ya que sugiere que el equilibrio trabajo–vida es sensible tanto a prácticas organizativas (autonomía, control y supervisión) como a contextos institucionales y culturales que varían por país.

Este punto es crucial para el TFG: si la conciliación depende de recursos (control del tiempo, autonomía, energía) y de demandas (intensidad, presión temporal, conectividad), entonces tecnologías como la IA generativa pueden operar como recurso (reduciendo fricción cognitiva, automatizando tareas) o como demanda (acelerando ritmos, elevando expectativas de disponibilidad). Esta lógica será la base para formular hipótesis direccionales y seleccionar variables outcome en la EWCS.

### **2.1.1. Dimensiones del equilibrio: satisfacción, funcionamiento y recursos personales**

En la investigación reciente, se ha reforzado la idea de que el equilibrio trabajo-vida/no-trabajo no es un único estado, sino que puede descomponerse en dimensiones que capturan distintos aspectos de la experiencia. Hildenbrand et al. (2024) trabajan explícitamente con una definición de work-nonwork balance (WNW) como multidimensional, distinguiendo entre dos dimensiones centrales: balance satisfaction (satisfacción con el equilibrio percibido) y balance effectiveness (capacidad de funcionar y cumplir expectativas en los roles de trabajo y no-trabajo). Su evidencia muestra que ambas dimensiones no siempre se comportan igual: en su modelo, el apoyo del supervisor se asocia con resultados como satisfacción vital y desempeño, pero los mecanismos pueden depender más de la efectividad del equilibrio que de la satisfacción declarada (Hildenbrand et al., 2024). Esta distinción resulta útil para este TFG porque permite mapear outcomes que, en encuestas como la EWCS, capturan tanto percepciones globales de encaje/compatibilidad como indicadores más “funcionales” ligados a presión temporal o interferencias.

Además, la conciliación puede interpretarse como un recurso psicológico dentro del marco de conservation of resources (COR). Desde esta perspectiva, niveles altos de WLB implican mayor disponibilidad de recursos (por ejemplo, tiempo y control percibido) que protegen frente al estrés y favorecen resultados positivos; en cambio, el desequilibrio se asocia con pérdida de recursos y desgaste (Hobfoll, 1989; Haar & Brougham, 2022). En consecuencia, condiciones laborales que drenan recursos (sobrecarga, presión temporal, falta de autonomía) tenderán a reducir WLB, mientras que condiciones que aportan recursos (control, apoyo, autonomía) tenderán a mejorarla (Haar & Brougham, 2022).

### **2.1.2. Relevancia de la WLB: por qué es un indicador central de calidad del empleo**

La WLB es un indicador especialmente valioso porque sintetiza una dimensión central de la calidad del empleo: no solo cuánto se trabaja, sino cómo se experimenta el trabajo en términos de presión temporal, recuperación y límites entre la esfera laboral y la vida no laboral. En términos organizativos, la conciliación se asocia con outcomes relevantes para el rendimiento sostenible: cuando los empleados alcanzan niveles más altos de WLB, se observan vínculos con actitudes y comportamientos laborales clave (por ejemplo, satisfacción, compromiso e intención de rotación), al menos en evidencia empírica que modela antecedentes y consecuencias del equilibrio (Haar & Brougham, 2022). Desde la óptica de la gestión, esto implica que la conciliación no es un “extra” de bienestar, sino un factor que condiciona la retención y el desempeño a medio plazo.

Además, la relevancia de la WLB puede situarse dentro de un marco normativo e institucional más amplio: el de Trabajo Decente (Decent Work) impulsado por la Organización Internacional del Trabajo (OIT/ILO). La Agenda de Trabajo Decente promueve oportunidades para mujeres y hombres de acceder a trabajo productivo en condiciones de libertad, equidad, seguridad y dignidad humana, y se articula en objetivos estratégicos que incluyen la promoción de derechos en el trabajo, el empleo, la protección social y el diálogo social (Ferraro et al., 2016). En este marco, la conciliación se conecta directamente con la calidad del empleo porque afecta a la sostenibilidad del trabajo en el tiempo (capacidad de recuperación, organización razonable de jornadas y compatibilidad con la vida personal), y porque constituye un componente práctico de condiciones laborales “dignas” más allá del salario o del estatus contractual. En particular, la literatura sobre trabajo decente subraya la importancia de condiciones temporales razonables y de la posibilidad de compatibilizar trabajo y vida personal como elementos sustantivos del concepto (Ferraro et al., 2016). Este énfasis institucional se

refuerza con la Agenda 2030 de Naciones Unidas, donde el Trabajo Decente se incorpora como el Objetivo de Desarrollo Sostenible 8 (ODS 8) (Ferraro et al., 2016). En consecuencia, la WLB puede interpretarse como una dimensión coherente con la evaluación del progreso hacia empleo de calidad y crecimiento sostenible: si la transformación del trabajo (digitalización, nuevas tecnologías o cambios en la organización) mejora la productividad, pero deteriora la capacidad de desconexión, incrementa la fatiga o amplía la disponibilidad fuera de horario, esa mejora sería discutible desde el punto de vista del trabajo decente.

Más aún, una parte relevante de la literatura insiste en que las organizaciones a menudo apoyan “familia” (work-family) pero no necesariamente el equilibrio con “la vida” en sentido amplio (ocio, salud, cuidados no infantiles, comunidad). Precisamente por ello, Haar & Harris (2025) argumentan que la literatura ha prestado insuficiente atención al apoyo organizativo específicamente orientado a WLB (no solo “family support”), y muestran que un constructo de apoyo organizativo dirigido a WLB (OS-WLB) mantiene una influencia significativa sobre la conciliación incluso controlando otras formas de apoyo (Haar & Harris, 2025). Esta idea conecta directamente con el enfoque “sentido amplio” del presente TFG: si el objetivo es evaluar la conciliación en el mercado laboral de la UE, resulta crucial medir dimensiones de WLB que capturen la vida no laboral en general y no únicamente el ámbito familiar.

### **2.1.3. Implicaciones metodológicas: de políticas “en papel” a apoyo real y normas de uso**

Una implicación relevante del marco anterior es que la conciliación no depende solo de la existencia formal de medidas (por ejemplo, teletrabajo o flexibilidad), sino de cómo esas medidas se traducen en apoyo real y en normas que permiten su uso. Fan et al. (2021) distinguen componentes “estructurales” (existencia/cantidad de apoyos) y “funcionales” (evaluaciones perceptivas), incluyendo elementos como disponibilidad percibida, expectativas y normas sobre el uso de apoyos. Esto es metodológicamente importante para la EWCS porque anticipa que variables observables (p. ej., teletrabajo o digitalización) pueden tener efectos distintos según el contexto organizativo y las expectativas sobre disponibilidad (Fan et al., 2021).

Esto justifica que, en este TFG, además de medir outcomes de WLB, se incluyan variables de contexto (autonomía, intensidad del trabajo, teletrabajo y exposición a sistemas digitales/IA generativa) como condiciones del efecto, dado que la literatura sugiere que los apoyos y su uso

efectivo dependen de normas, expectativas y características del entorno organizativo (Fan et al., 2021; Vyas, 2022; Lee, 2024).

En síntesis, el marco teórico desarrollado en los epígrafes anteriores permite identificar dos mecanismos principales mediante los que la IA generativa puede influir en la conciliación vida-trabajo: un canal de eficiencia (recurso), que tendería a mejorar el encaje global y reducir la interferencia por tiempo, y un canal de conectividad e intensificación (demanda), que ampliaría el trabajo fuera de horario y la interferencia por tensión. El efecto neto sobre cada dimensión dependerá de las condiciones organizativas, especialmente de la autonomía, la intensidad del trabajo y el teletrabajo, de acuerdo con las hipótesis H1–H5 derivadas a lo largo de la revisión. La Sección 3 operacionaliza estas dimensiones e hipótesis con datos de la EWCS 2024/2025.

## **2.2 Digitalización, flexibilidad y teletrabajo: oportunidades y riesgos**

La digitalización del trabajo y la expansión del teletrabajo han reconfigurado la relación entre tiempo laboral, espacio de trabajo y vida personal. En el “new normal” post-pandemia, se han consolidado arreglos híbridos y herramientas digitales que permiten trabajar con mayor flexibilidad temporal y geográfica, pero también pueden diluir límites y favorecer dinámicas de conectividad constante (Vyas, 2022). Desde el punto de vista de la conciliación, el teletrabajo puede actuar como recurso cuando reduce desplazamientos y mejora el control del tiempo; sin embargo, la evidencia sugiere que la flexibilidad no garantiza automáticamente una mejor WLB: puede intensificar la mezcla trabajo-hogar y aumentar la probabilidad de dinámicas de conectividad constante, extendiendo la disponibilidad fuera del horario habitual y dificultando la recuperación (Vyas, 2022; Haar & Brougham, 2022).

Vyas (2022) enfatiza que el efecto de la flexibilidad depende del diseño organizativo: prácticas de control, gestión del desempeño, apoyo del supervisor y expectativas de respuesta pueden transformar la flexibilidad en mayor equilibrio o, por el contrario, en extensión de jornada y presión temporal. Esta idea conecta con el marco JD–R (Bakker & Demerouti, 2007): el teletrabajo no es en sí mismo un recurso o una demanda, sino que su efecto sobre la conciliación depende de si el entorno organizativo lo acompaña con normas que protejan el tiempo personal y reduzcan la ambigüedad de rol (Fan et al., 2021). Esta ambivalencia es especialmente relevante para estudiar IA generativa porque su adopción se produce típicamente en entornos altamente digitalizados donde teletrabajo, herramientas colaborativas y métricas de desempeño

ya están presentes (Vyas, 2022). Por tanto, para analizar el efecto de IA sobre conciliación, es clave considerar el teletrabajo como un posible moderador: puede reforzar canales de eficiencia (más autonomía) o amplificar canales de conectividad y presión (más disponibilidad y menor desconexión).

### **2.3. IA en el trabajo (incluida IA generativa): bienestar, control y gestión algorítmica**

En este TFG se plantea que la IA generativa puede afectar de forma heterogénea a las dimensiones de conciliación analizadas. En concreto, se distinguen tres canales principales:

- Canal de eficiencia (recurso): la IA generativa puede reducir fricción cognitiva y ahorrar tiempo, lo que tendería a mejorar el encaje global trabajo–vida (D1) y reducir la interferencia por tiempo (D2) (Lee, 2024; Vyas, 2022).
- Canal de conectividad/intensificación (demanda): la IA generativa puede acelerar ciclos de respuesta y elevar expectativas de disponibilidad, aumentando el trabajo fuera de horario/boundaryless work (D3) y la interferencia por tensión/agotamiento (D4) (Vyas, 2022; Lee, 2024; Chen & Li, 2024).
- Canal contextual (condiciones del efecto): el impacto neto dependerá del entorno organizativo, especialmente de los facilitadores y normas de apoyo a la conciliación (D5), así como de variables de contexto como autonomía, intensidad y teletrabajo (Fan et al., 2021; Haar & Harris, 2025).

La adopción de IA en el trabajo se asocia a promesas de productividad y apoyo cognitivo, pero también a riesgos sobre control, estrés e inseguridad. La revisión de Lee (2024), basada en literatura reciente sobre integración de IA y bienestar, destaca que los efectos de la IA sobre el bienestar de los empleados no son unívocos: pueden aparecer resultados positivos (apoyo a tareas, eficiencia) y negativos (estrés, inseguridad laboral, alteraciones del significado del trabajo), dependiendo del contexto y de cómo se implementa la tecnología (Lee, 2024). Esta conclusión es clave para este TFG: la IA generativa no debe modelarse como “buena” o “mala” per se, sino como un cambio tecnológico cuyo impacto sobre la conciliación depende del equilibrio entre demandas y recursos y de las condiciones organizativas.

Un punto especialmente relevante para la conciliación es la coexistencia entre IA generativa (herramientas de apoyo: redacción, búsqueda, síntesis) y sistemas de gestión digital/algorítmica que fijan ritmos, monitorizan o influyen en decisiones de desempeño. Lee (2024) recoge que la percepción de ser evaluado o gestionado por sistemas basados en IA puede asociarse con estrés y preocupación, particularmente cuando aumenta la supervisión o disminuye la discrecionalidad percibida (Lee, 2024; Zhang et al., 2025; Parent-Rochelleau & Parker, 2022). En términos de WLB, estas dinámicas pueden operar como mecanismos de intensificación (más presión temporal) y de conectividad (expectativas de respuesta), afectando dimensiones como la capacidad de desconexión y el control del tiempo.

En línea con los canales anteriores, en el caso específico de la IA generativa su impacto potencial sobre la conciliación puede entenderse como un equilibrio entre ganancias de eficiencia (liberación de tiempo/energía) y nuevas demandas (mayor velocidad, disponibilidad y volumen). Por ello, el efecto final sobre las dimensiones de WLB dependerá de si predominan las mejoras en eficiencia y control del tiempo o, por el contrario, la intensificación y la conectividad fuera del horario laboral (Vyas, 2022; Lee, 2024; Chen & Li, 2024).

El uso de IA generativa en el trabajo se asocia con un mejor encaje global trabajo–vida, al liberar recursos temporales y cognitivos mediante ganancias de eficiencia (Vyas, 2022; Lee, 2024). Por lo tanto, nuestra hipótesis se formula de la siguiente manera:

*H1 (+): el uso de la IA generativa en el trabajo se asocia positivamente a un mayor encaje global trabajo-vida.*

Este canal positivo es, sin embargo, contingente: las ganancias de eficiencia solo se traducen en mejor conciliación si la organización permite que el tiempo liberado revierta al trabajador, y no se absorbe en mayor volumen de trabajo o en expectativas crecientes de productividad (Fan et al., 2021). El uso de IA generativa se asocia con menor interferencia por tiempo, al reducir la carga de tareas intensivas en información y ampliar la capacidad de gestión del tiempo dentro de la jornada (Fan et al., 2021; Lee, 2024). Al igual que en H1, la realización de este potencial depende de que los recursos temporales liberados no sean sustituidos por nuevas demandas, lo que convierte las normas y expectativas organizativas en una condición necesaria para que el canal de eficiencia opere en la dirección predicha. Nuestra segunda hipótesis es la siguiente:

*H2 (+): La IA generativa se asocia positivamente con menor interferencia por tiempo en la vida familiar del trabajador.*

Estos dos mecanismos positivos se derivan del canal de eficiencia y constituyen las dimensiones de WLB donde, bajo condiciones organizativas favorables, cabe esperar efectos beneficiosos de la IA generativa. Su no confirmación empírica es, por ello, teóricamente coherente: si las ganancias de eficiencia son capturadas por la organización en forma de mayor carga, el canal positivo queda neutralizado.

#### **2.4. Marco integrador: recursos, demandas y apoyos para explicar la relación IA - WLB**

El marco que articula mejor la ambivalencia anterior es un enfoque de recursos y demandas, combinando la lógica COR y la conceptualización de apoyos a la conciliación. Fan et al. (2021) proponen entender el apoyo a la conciliación como una inversión de recursos externos que permite a las personas expandir o asignar mejor sus recursos personales para responder a estresores, formando potencialmente un ciclo virtuoso de inversión y retorno de recursos. En paralelo, la interpretación de WLB como recurso psicológico sugiere que niveles altos de equilibrio implican mayor control y mejor capacidad de organizar tareas y roles, mientras que niveles bajos se asocian a mayor desgaste y pérdida de recursos (Haar & Brougham, 2022).

Trasladado a la IA generativa, este marco permite formular una lógica clara: la IA puede actuar como recurso si reduce fricción cognitiva (búsqueda, síntesis, redacción), libera tiempo y aumenta eficacia; pero también como demanda si eleva expectativas de velocidad, incrementa el volumen de tareas o facilita prácticas de supervisión/monitorización que intensifican el trabajo (Fan et al., 2021; Lee, 2024; Bakker & Demerouti, 2017). Por tanto, el efecto neto sobre la conciliación dependerá de qué canal domine y bajo qué condiciones organizativas.

#### **2.5. El “doble efecto” tecnológico: mejora vs. estrés por reemplazo e intensificación**

La coexistencia de efectos positivos y negativos de la tecnología se documenta de forma explícita en Chen & Li (2024), quienes analizan la automatización y muestran que pueden coexistir un efecto de mejora (improvement effect) y un estrés por reemplazo (replacement

stress). En su planteamiento, la automatización puede mejorar resultados cuando se traduce en mejores condiciones o mayor eficiencia, pero puede reducir la satisfacción cuando los empleados perciben que su puesto es fácilmente reemplazable por tecnología (Chen & Li, 2024). Aunque su outcome principal es satisfacción laboral, el mecanismo es trasladable a la conciliación: el estrés por reemplazo puede elevar carga mental y preocupación, dificultando la desconexión y la recuperación, mientras que las ganancias de eficiencia podrían liberar recursos (tiempo y energía) relevantes para WLB. El uso de IA generativa se asocia con mayor boundaryless work (más trabajo fuera de horario), al acelerar ciclos de respuesta e incrementar expectativas de disponibilidad y conectividad (Vyas, 2022; Lee, 2024). Por este motivo, nuestra tercera hipótesis versa de la siguiente manera:

*H3 (-): El uso de IA generativa se asocia con mayor boundaryless work (más trabajo fuera de horario) y por tanto, con un menor equilibrio vida laboral-familiar.*

Además, Chen & Li (2024) subrayan que los efectos no se distribuyen de forma uniforme, sino que varían por características del trabajador y del puesto. Esta heterogeneidad tiene dos implicaciones para el presente TFG. Por un lado, refuerza la necesidad de examinar interacciones para identificar cuándo la IA se asocia más a "recurso" o a "demanda". Por otro lado, sugiere que el impacto sobre la tensión cognitiva y el agotamiento fuera del horario puede ser especialmente intenso entre quienes ya asumen mayor carga o responsabilidad, dado que la tecnología amplifica tanto la capacidad de producción como las expectativas asociadas a ella (Chen & Li, 2024; Lee, 2024). El uso de IA generativa se asocia con mayor interferencia por tensión y agotamiento, consistente con el estrés por intensificación y la presión cognitiva derivados de la adopción tecnológica (Lee, 2024; Chen & Li, 2024). Por estas razones, nuestra cuarta hipótesis se formula de la siguiente manera:

*H4 (-): El uso de IA generativa se asocia con mayor interferencia por tensión y agotamiento, causados por la intensificación del trabajo, y con un menor equilibrio de la vida laboral y familiar.*

La heterogeneidad de estos efectos negativos refuerza la necesidad de examinar subgrupos e interacciones para determinar cuándo predomina el canal de intensificación frente al de eficiencia.

## **2.6. Moderadores organizativos: autonomía, intensidad y teletrabajo del efecto de la IA**

La literatura sugiere que el efecto de tecnologías digitales sobre bienestar y conciliación depende del diseño del trabajo. En entornos flexibles, variables como supervisión, expectativas y claridad de límites pueden transformar la digitalización en mayor conciliación o en extensión de jornada (Vyas, 2022). A su vez, la evidencia sobre WLB destaca que demandas percibidas (work demands) tienden a relacionarse negativamente con el equilibrio, mientras que recursos como autonomía/control se relacionan positivamente (Haar & Brougham, 2022). Esta lógica es especialmente relevante para IA generativa: si se introduce en puestos con alta presión temporal y baja autonomía, es plausible que amplifique intensificación; en puestos con mayor control, puede traducirse más en eficiencia y liberación de tiempo.

Finalmente, el papel del apoyo organizativo también es central. Fan et al. (2021) muestran que los mecanismos de apoyo y su percepción (disponibilidad, expectativas, legitimidad de uso) forman parte del proceso por el que el individuo convierte “existencia” de recursos en conciliación real. En la misma línea, Haar & Harris (2025) encuentran que el apoyo organizativo específicamente orientado a WLB (más allá de la familia) se relaciona de forma significativa con el equilibrio percibido, lo que sugiere que las políticas y señales organizativas pueden amortiguar impactos negativos asociados a la digitalización (Haar & Harris, 2025). Para este TFG, esto justifica empíricamente incorporar moderadores como autonomía, intensidad y teletrabajo, e interpretar la exposición a IA dentro de un entorno organizativo más amplio. Por lo tanto, la quinta hipótesis es:

*H5 (+): El uso de IA generativa se asocia con mayor predictibilidad del horario de trabajo por parte del empleador.*

El mecanismo propuesto es el siguiente: la IA generativa puede contribuir a una mejor planificación y gestión de la carga de trabajo, a través de la automatización de tareas de coordinación, la anticipación de plazos y la reducción de incertidumbre operativa, lo que facilitaría que los empleadores puedan comunicar y respetar los horarios con mayor consistencia (Fan et al., 2021; Haar & Harris, 2025). Además, los trabajadores que usan IA tienden a operar en entornos organizativos más maduros en términos de gestión digital, lo que se asocia con mejores prácticas de planificación y apoyo a la conciliación (Vyas, 2022). No obstante, este argumento es indirecto y dependiente del diseño organizativo: si la IA se utiliza

para intensificar la carga o alargar jornadas, el efecto sobre la predictibilidad horaria puede ser nulo o negativo, lo que hace de H5 la hipótesis con mayor incertidumbre a priori del conjunto. Además de las cinco hipótesis principales, este trabajo incorpora términos de interacción entre el uso de IA generativa y los tres moderadores organizativos. El diseño del estudio es primariamente confirmatorio respecto a H1–H5, pero adopta un enfoque exploratorio en lo relativo a las interacciones, reconociendo que la evidencia empírica sobre los mecanismos moderadores en el contexto específico de la IA generativa es todavía incipiente. No obstante, con base en la literatura revisada se formulan las siguientes expectativas de dirección: (H3a) el efecto negativo de la IA sobre el trabajo en tiempo libre (D3) se amplifica cuando la intensidad laboral es alta, dado que la combinación de mayor carga y mayor velocidad favorece el desbordamiento temporal (Vyas, 2022; Bakker & Demerouti, 2007); (H2a) el impacto de la IA sobre la interferencia temporal (D2) se modera por la autonomía laboral: en entornos con mayor control sobre el propio trabajo, el canal de eficiencia puede operar con mayor eficacia; y (H4a) el efecto de la IA sobre la interferencia por tensión (D4) se amplifica cuando la autonomía es alta, en tanto que los trabajadores con mayor control asumen también mayor responsabilidad sobre los resultados asistidos por IA, con mayor potencial de carga cognitiva (Haar & Brougham, 2022). La confirmación o refutación de estas expectativas se discute en la Sección 4.7 junto con los resultados de las interacciones estimadas en M3.

**Tabla 2.1. Síntesis de hipótesis del estudio**

Hipótesis	Signo esperado	Dimensión	Mecanismo teórico
H1	(+)	D1 – Encaje global trabajo-vida	Canal de eficiencia: la IA generativa reduce fricción cognitiva (redacción, síntesis, búsqueda) y libera recursos temporales, lo que mejora la evaluación subjetiva global del equilibrio trabajo-vida (Lee, 2024; Vyas, 2022).
H2	(+)	D2 – Interferencia trabajo-familia basada en tiempo	Canal de eficiencia aplicado al dominio familiar: al reducir la carga de tareas y ampliar la capacidad de gestión del tiempo dentro de la jornada, la IA generativa reduciría la interferencia del trabajo sobre el tiempo familiar (Fan et al., 2021; Lee, 2024).
H3	(–)	D3 – Trabajo fuera del horario laboral	Canal de intensificación/conectividad: al acelerar ciclos de respuesta, reducir la fricción de las tareas y elevar expectativas de disponibilidad, la IA generativa favorece el desbordamiento temporal hacia el tiempo libre (Vyas, 2022; Lee, 2024; Chesley, 2014; Derks et al., 2016).

H4	(-)	D4 – Interferencia por tensión cognitiva	Doble efecto tecnológico: la IA generativa eleva expectativas de productividad (estrés por aceleración/reemplazo) y mantiene la mente anclada al trabajo fuera del horario, amplificando la tensión cognitiva (Chen & Li, 2024; Lee, 2024; Baumeister et al., 2021; Azpíroz-Dorronsoro et al., 2024).
H5	(+)	D5 – Predicibilidad del horario	Hipótesis indirecta y contingente: la IA generativa podría mejorar la planificación y anticipación de cargas, facilitando que los empleadores comuniquen y respeten horarios con mayor consistencia. Efecto dependiente del diseño organizativo (Fan et al., 2021; Haar & Harris, 2025).

Nota: Signo (+) indica asociación predicha con mejor WLB; signo (-) indica asociación predicha con peor WLB. H1–H5 son las hipótesis principales contrastadas en §4.2–§4.6. Fuente: Elaboración propia.

### 3. Metodología de Investigación

#### 3.1. Descripción de la base de datos: European Working Conditions Survey 2024/2025

La fuente de datos principal de este estudio es la European Working Conditions Survey (EWCS) 2024/2025, promovida y financiada por Eurofound (Fundación Europea para la Mejora de las Condiciones de Vida y de Trabajo). La EWCS es la encuesta de referencia a nivel europeo para el análisis de las condiciones de empleo, la organización del trabajo, el bienestar y los factores psicosociales en el mercado laboral. Su diseño permite la comparabilidad internacional entre países, convirtiéndola en una fuente idónea para evaluar la relación entre la adopción de IA generativa y la conciliación vida–trabajo en el contexto de la Unión Europea (Eurofound, 2025).

El microdato disponible comprende 36.644 observaciones correspondientes a personas ocupadas en 35 países, incluyendo los 27 Estados miembros de la UE (UE-27) más ocho países candidatos o terceros. La muestra de UE-27 asciende a 28.621 individuos, que constituyen la población de referencia principal de este estudio. La unidad de análisis es el individuo ocupado, asalariado o autónomo, entrevistado sobre sus condiciones laborales, experiencias en el trabajo y situación personal.

La EWCS emplea un diseño muestral complejo con estratificación por país, sector NACE y tamaño del centro de trabajo, con selección de hogares mediante muestreo polietápico. Cada

país dispone de aproximadamente 1.000 entrevistas, con excepciones en países de mayor tamaño (Alemania: 1.062; Francia: 1.052; Bélgica: 2.053) o menor (Luxemburgo: 512). Las estadísticas descriptivas se calcularon incorporando las ponderaciones muestrales proporcionadas, y en los modelos se reportaron errores estándar robustos con pruebas de comparación con y sin ponderación y con errores agrupados por país.

La edición 2024/2025 incorpora por primera vez un módulo específico sobre tecnologías digitales en el trabajo, incluyendo un ítem dedicado a la IA generativa (tech\_genAI), herramientas de monitorización del rendimiento (tech\_monitor\_perf) y otros sistemas digitales de gestión. En la muestra UE-27, el 11,2% de los trabajadores declara utilizar IA generativa en su trabajo (88,8% no lo hace), con una variación sustancial entre países: desde el 2,7% en Rumania o el 3,3% en Portugal hasta el 21,8% en Dinamarca o el 21,2% en Suecia. Este grado de heterogeneidad cross-country justifica el uso de efectos fijos de país en los modelos estimados y permite analizar si las diferencias institucionales y culturales moderan la relación entre IA y WLB.

Como toda encuesta transversal y auto-declarada, la EWCS presenta limitaciones que deben tenerse en cuenta. La naturaleza observacional de los datos impide la inferencia causal directa: las asociaciones estimadas pueden estar afectadas por endogeneidad si la adopción de IA generativa correlaciona con características no observables (cultura organizativa, capacidades digitales previas). Además, la variable de IA generativa es binaria (usa/no usa), lo que impide distinguir la intensidad de uso o el tipo específico de herramienta. Por último, al dirigirse al trabajador individual, no se dispone de información sobre políticas organizativas de IA. Estas limitaciones se abordan mediante pruebas de robustez descritas en la Sección 3.8.

### **3.2. Clasificación de los países de la muestra**

Con el objetivo de contextualizar los resultados y analizar la heterogeneidad institucional que caracteriza el mercado laboral de la UE, se ha procedido a clasificar los 27 países de la muestra en clusters siguiendo el marco de las "Variedades del Capitalismo" (Hall & Soskice, 2001) y los regímenes de bienestar de Esping-Andersen, adaptados al contexto de la digitalización laboral y las políticas de conciliación (Hall & Soskice, 2001; Esping-Andersen, 1990).

Esta clasificación es relevante porque el contexto regulatorio e institucional condiciona tanto el ritmo de adopción de la IA generativa como la disponibilidad de mecanismos de protección

de la WLB (derecho a la desconexión, cobertura de negociación colectiva, marcos de flexibilidad-seguridad). Como se observa en la Tabla 3.1 y en los análisis descriptivos (Figuras 3.1 y 3.3), la variación cross-country en adopción de IA es sustancial, lo que justifica el uso de efectos fijos de país en los modelos de regresión.

Un elemento estructural relevante del mercado laboral europeo que se desprende de los datos es el elevado peso de las pequeñas y medianas empresas (pymes). En la muestra UE-27 de la EWCS 2024/2025, el 69,3% de los trabajadores presta sus servicios en centros de trabajo con menos de 250 empleados (definición de pyme según la Comisión Europea). Este porcentaje varía entre clusters, con mayor peso en Europa del Este y el sur mediterráneo, y tiene implicaciones directas para el análisis de la adopción de IA generativa: las pymes presentan menores tasas de digitalización avanzada, menor capacidad de inversión en herramientas de IA y, en ocasiones, marcos de conciliación menos formalizados. Esta heterogeneidad se captura mediante la variable `wp_size` en los modelos y se explora específicamente en el análisis de subgrupos de la Sección 3.8.

**Tabla 3.1.** Clasificación de países UE-27 por clúster institucional

Tabla 3.1. Clasificación de países UE-27 por clúster institucional. Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

Cluster	Países (N)	N muestra	Adopción IA (%)	Peso pymes (%)
Nórdico	DK, FI, SE (3)	3,029	20.3%	60.7%
Continental	AT, BE, DE, LU, NL (5)	5,780	18.0%	55.6%
Liberal	IE (1)	1,107	11.3%	60.4%
Mediterráneo	CY, ES, FR, GR, IT, MT, PT (7)	6,962	7.1%	76.3%
Europa del Este	BG, CZ, EE, HR, HU, LT, LV, PL, RO, SI, SK (10)	11,743	7.9%	75.0%
TOTAL UE-27	27 países	28,621	11.2%	69.3%

Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.3. Diseño del estudio y enfoque analítico

Dado el objetivo del estudio, examinar relaciones entre variables observables en una muestra amplia y representativa, la metodología cuantitativa es la más adecuada. Este enfoque permite la identificación de patrones estadísticos y la contrastación de hipótesis sobre una muestra de 25.138 trabajadores de 27 países, proporcionando un marco estructurado para obtener conclusiones generalizables (Saunders, Lewis & Thornhill, 2023). La European Working Conditions Survey, con su cobertura multinacional y sus respuestas estandarizadas, es especialmente compatible con este enfoque al facilitar el análisis inferencial y la comparabilidad internacional.

Este Trabajo Fin de Grado utiliza un enfoque cuantitativo, observacional y comparativo para evaluar la relación entre la adopción de IA generativa y la conciliación vida–trabajo entre los trabajadores de la UE. La naturaleza de los datos, una encuesta transversal de sección cruzada con cobertura multinacional, impone un marco de análisis correlacional: los resultados se interpretan como asociaciones estadísticas netas y no como efectos causales, dado que no es posible descartar confusión residual.

La estrategia empírica sigue una estructura stepwise en tres etapas, siguiendo una lógica acumulativa, en una primera etapa (Modelo 1) se estima únicamente el bloque de variables de control sociodemográficas y laborales, estableciendo una línea base; en la segunda etapa (Modelo 2) se añade la variable principal de exposición a IA generativa junto con los moderadores (autonomía, intensidad laboral, teletrabajo); en la tercera etapa (Modelo 3) se incorporan los términos de interacción entre IA generativa y los moderadores, permitiendo analizar heterogeneidad en el efecto.

Para capturar la naturaleza multidimensional de la conciliación, el análisis se organiza en torno a cinco dimensiones de outcome (D1–D5), cada una estimada mediante una regresión OLS independiente con errores estándar robustos HC3. Este estimador se aplica de forma uniforme a todas las variables dependientes, que han sido estandarizadas e invertidas siguiendo un criterio específico por dimensión: en D1 (encaje global) y D5 (predicibilidad horaria) un valor mayor indica mejor WLB, mientras que en D2, D3 y D4 un valor mayor indica más interferencia o desbordamiento (peor WLB). La dirección del coeficiente de cada dimensión se interpreta explícitamente en las sub-secciones §4.2–§4.6. Como prueba de robustez se estiman modelos ordered logit sobre los ítems ordinales individuales, cuyos resultados confirman la estabilidad del patrón principal. Todos los modelos incluyen efectos fijos de país y dummies de ocupación (ISCO-1) y sector (NACE). La elección de OLS frente a modelos ordenados (ordered logit o probit) responde a dos criterios. En primer lugar, las variables dependientes han sido invertidas y estandarizadas, lo que las aproxima a una escala continua y permite interpretar los coeficientes directamente como diferencias en puntos de la escala de WLB. En segundo lugar, la literatura metodológica señala que OLS produce estimaciones consistentes y fácilmente interpretables cuando el número de categorías es suficiente y las distribuciones no presentan censura extrema, condiciones que se verifican en los datos (Haar,

2013). Los modelos ordered logit se utilizan como prueba de robustez y confirman la estabilidad cualitativa de los resultados.

### **3.4. Análisis descriptivo**

Con carácter previo a la estimación de los modelos de regresión, se realiza un análisis descriptivo exhaustivo de las variables del estudio. Este análisis cumple una triple función: en primer lugar, permite verificar la calidad y distribución de los datos (valores ausentes, outliers, asimetría); en segundo lugar, documenta las características de la muestra y contextualiza la variación de las variables clave; en tercer lugar, anticipa las relaciones bivariadas entre la exposición a IA generativa y las dimensiones de WLB, antes de controlar por covariables.

#### **3.4.1. Estadísticos descriptivos**

La Tabla 3.2 presenta los estadísticos descriptivos de todas las variables del modelo para la muestra UE-27 (N=28.621). La tasa de valores ausentes es baja en la mayoría de variables, con dos excepciones relevantes: `contact_out_wh` (16,8% missing, derivado del filtro de aplicabilidad de la pregunta) y `empl_contract` (16,1%, por restricción a asalariados). Estas dos situaciones determinan decisiones de diseño que se detallan a continuación. En lo que respecta a la variable de contrato indefinido (`empl_contract / permanent`), se ha optado por excluirla del modelo base por dos razones: (i) su elevada tasa de valores ausentes (16,1%) reduciría innecesariamente la muestra de estimación; y (ii) su inclusión en modelos con múltiples efectos fijos de país y sector introduce redundancia con la estructura institucional ya captada por esos efectos fijos. La variable `permanent` se incluye únicamente en los análisis de sensibilidad descritos en la Sección 3.8, donde se verifica que su inclusión no altera los coeficientes principales. En lo que respecta a D3 (trabajo fuera del horario laboral), la variable preferida en la literatura sería `contact_out_wh` (contacto fuera del horario habitual), pero su 16,8% de valores ausentes, derivado del filtro de aplicabilidad de la pregunta, habría reducido significativamente la muestra y generado potencial sesgo de selección. Por ello, D3 se operacionaliza mediante `freetime_work` (frecuencia con la que el trabajador dedica tiempo libre al trabajo), que no presenta este problema de cobertura y captura la misma dimensión teórica de desbordamiento temporal del trabajo hacia la vida personal.

**Tabla 3.2.** Estadísticos descriptivos de las variables del modelo

Tabla 3.2. Estadísticos descriptivos (UE-27, N=28.621). Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

Variable	Escala	N	Media	DE	Mín.	Máx.	Missing %
D1: Encaje global WLB	1-4 (inv.)	28.538	3.122	0.753	1.0	4.0	0.3%
D2: Interf. tiempo-familia	1-5 (inv.)	27.745	2.249	1.088	1.0	5.0	3.1%
D3: Trabajo fuera de horario	1-5 (inv.)	28.516	1.800	1.028	1.0	5.0	0.4%
D4: Interf. por tensión	1-5 (inv.)	28.353	2.307	1.144	1.0	5.0	0.9%
D5: Predicibilidad horario	1-3 (inv.)	28.423	2.365	0.778	1.0	3.0	0.7%
IA generativa	0/1	28.493	0.112	0.315	0.0	1.0	0.4%
Teletrabajo	1-5 (inv.)	28.573	1.787	1.260	1.0	5.0	0.2%
Autonomía laboral	1-5	28.609	2.609	1.136	1.0	5.0	0.0%
Intensidad laboral	1-7 (inv.)	28.596	3.648	1.791	1.0	7.0	0.1%
Mujer	0/1	28.589	0.521	0.500	0.0	1.0	0.1%
Edad	años	28.523	45.286	13.369	16.0	74.0	0.3%
Educación baja	0/1	28.551	0.125	0.331	0.0	1.0	0.2%
Educación media	0/1	28.551	0.475	0.499	0.0	1.0	0.2%
Educación alta	0/1	28.551	0.399	0.490	0.0	1.0	0.2%
Horas semanales	1-80	27.300	37.070	11.357	1.0	80.0	4.6%
Pyme (≤249 emp.)	0/1	27.969	0.693	0.461	0.0	1.0	2.3%
Asalariado	0/1	28.396	0.845	0.362	0.0	1.0	0.8%

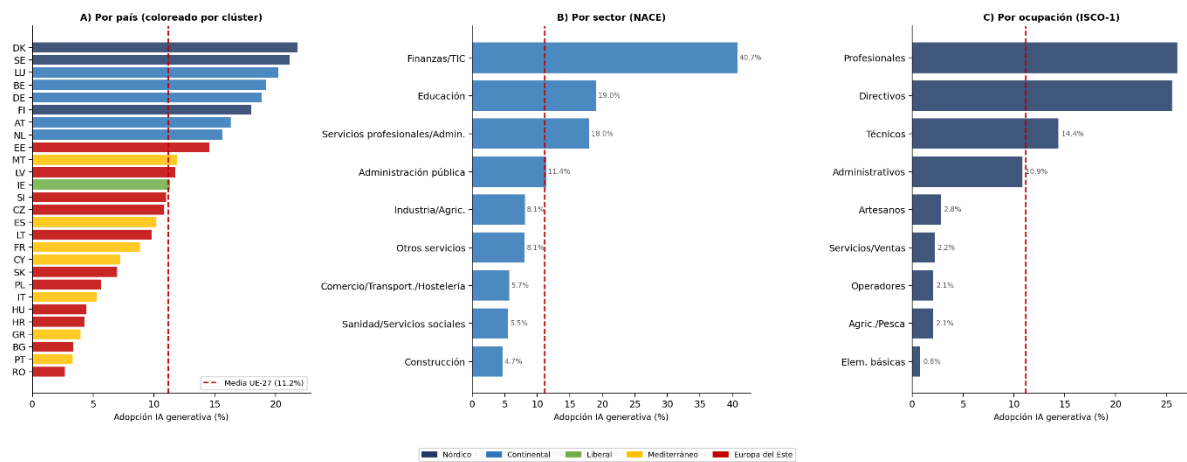
Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.4.2. Distribución de la variable explicativa: adopción de IA generativa

En la muestra UE-27, el 11,2% de los trabajadores declara utilizar herramientas de IA generativa en su trabajo. Esta cifra global esconde una heterogeneidad cross-country, cross-sectorial y cross-ocupacional muy relevante para la interpretación de los resultados (Figura 3.1).

Por países, la adopción oscila entre el 2,7% de Rumania y el 21,8% de Dinamarca, con una clara división entre los clusters Nórdico y Continental (>15%) y los clusters Mediterráneo y Europa del Este (<11% en casi todos los países). Por sectores, Finanzas/TIC y Servicios Profesionales presentan las tasas más elevadas, seguidos de Educación y Administración Pública, mientras que Construcción, Hostelería e Industria se sitúan por debajo de la media. Por ocupación, los Profesionales (ISCO-2) y Directivos (ISCO-1) lideran la adopción, frente a Operadores y Ocupaciones Elementales

**Figura 3.1. Distribución del uso de IA generativa por país, sector y ocupación**




Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.4.3. Comparación descriptiva WLB: usuarios vs. no usuarios de IA

La Figura 3.2 presenta la comparación de medias en las cinco medidas de WLB entre usuarios y no usuarios de IA generativa, sin controlar por covariables. Los resultados del test de Mann-Whitney muestran diferencias estadísticamente significativas en la mayoría de dimensiones. Los usuarios de IA generativa reportan, en media, un encaje global WLB ligeramente peor (D1), más interferencia temporal trabajo-familia (D2), más trabajo en tiempo libre (D3), mayor preocupación fuera del trabajo (D4) y mayor fatiga, pero no diferencias claras en los facilitadores organizativos (D5). Estas diferencias brutas, no controladas, anticipan los patrones esperados según las hipótesis del estudio y se examinarán con mayor rigor en los modelos multivariantes.

**Figura 3.2. Conciliación vida-trabajo: usuarios vs no usuarios de IA generativa**

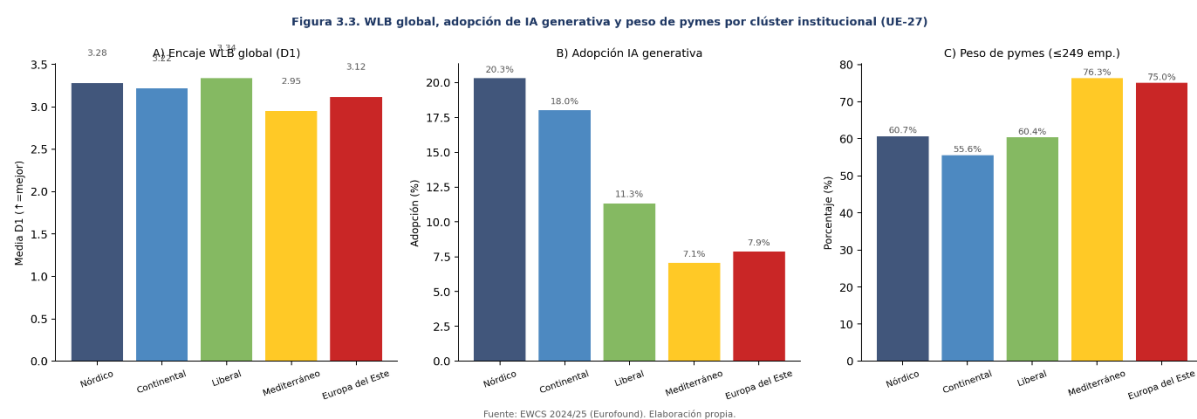


Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.4.4. WLB, adopción de IA y peso de pymes por cluster de país

La Figura 3.3 ilustra la variación de los tres indicadores clave, encaje global WLB, adopción de IA y presencia de pymes, a nivel de cluster. Los países Nórdicos presentan simultáneamente los mayores niveles de adopción de IA y los mejores resultados de WLB (media D1 más cercana a "Muy bien"), mientras que Europa del Este combina baja adopción de IA con WLB intermedia y alto peso de pymes. Este patrón descriptivo sugiere que los efectos de la IA sobre la WLB pueden estar moderados por el contexto institucional y la estructura empresarial, reforzando la necesidad de incluir efectos fijos de país y el subgrupo de pymes en el análisis.

**Figura 3.3.** WLB global, adopción de IA generativa y peso de pymes por clúster institucional

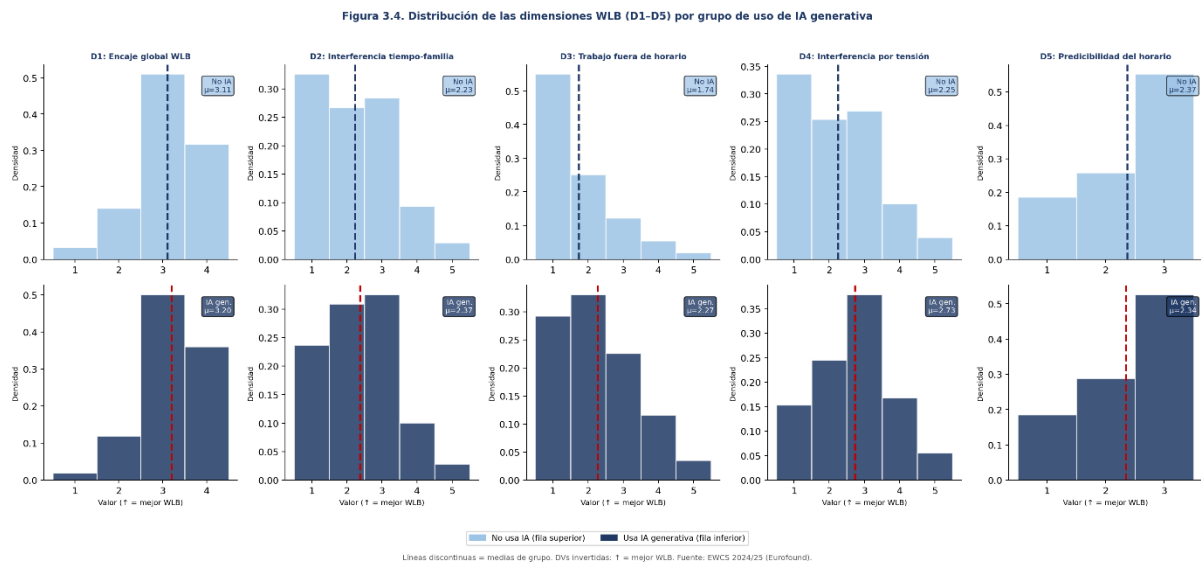


Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.4.5. Distribución de las variables dependientes

La Figura 3.4 presenta la distribución de las principales variables dependientes (D1, D2, D3, D4, D5) de forma desagregada por grupo de adopción de IA. El panel F muestra el perfil de medias comparativo para las cinco dimensiones WLB. Se observa que, en prácticamente todas las dimensiones, los usuarios de IA presentan una distribución ligeramente más desfavorable, consistente con la hipótesis del canal de intensificación, aunque las diferencias son modestas en términos absolutos, lo que apunta a la necesidad de controlar por covariables.

**Figura 3.4.** Distribución de las dimensiones WLB (D1-D5) por grupo de uso de IA generativa



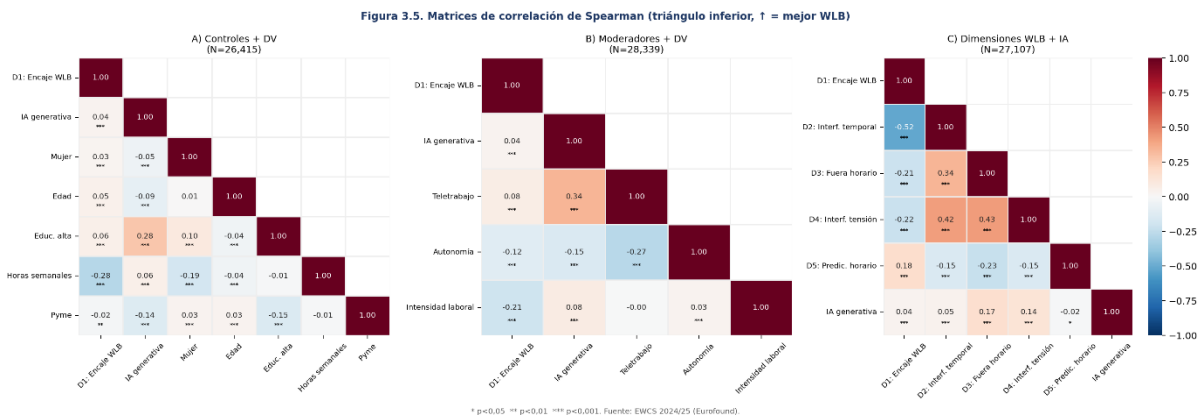
Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.5. Análisis de correlaciones

Se calcularon matrices de correlación de Spearman para los tres grupos de variables: controles + variable dependiente, moderadores + variable dependiente, y las cinco dimensiones WLB entre sí junto con la variable de IA generativa (Figura 3.5). Se utiliza el coeficiente de Spearman por su robustez ante variables ordinales y distribuciones no normales, características predominantes en el dataset EWCS.

Los resultados confirman la ausencia de correlaciones excesivamente elevadas entre los regresores, lo que anticipa la ausencia de multicolinealidad grave. La variable de IA generativa (tech\_genAI) presenta correlaciones positivas moderadas con el nivel educativo y el sector de actividad, lo que subraya la importancia de controlar por estas variables en los modelos. Las dimensiones WLB entre sí muestran correlaciones de moderadas a altas (especialmente entre D4a preocupación y D4b fatiga), lo que valida la decisión de tratarlas como dimensiones separadas en modelos independientes.

**Figura 3.5.** Matrices de correlación de Spearman (UE-27)



Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.6. Test de multicolinealidad (VIF)

Con el fin de verificar formalmente la ausencia de multicolinealidad entre los regresores del modelo completo, se calculó el Factor de Inflación de la Varianza (VIF) para cada variable del bloque de controles, la variable explicativa principal y los moderadores (Tabla 3.3). El VIF mide en qué medida la varianza del coeficiente estimado se infla por la correlación con otras variables; valores superiores a 10 se consideran problemáticos, y valores superiores a 5 señalan multicolinealidad moderada.

Los resultados del test VIF confirman la ausencia de multicolinealidad problemática en el modelo. Todos los regresores presentan  $VIF < 5$ , a excepción del par edad/edad<sup>2</sup>, cuyos VIFs de ~47 reflejan la correlación mecánica entre una variable y su cuadrado: este resultado es completamente esperado y no constituye un problema estadístico, ya que la inclusión del término cuadrático está teórica y empíricamente justificada: la relación entre edad y WLB sigue una curva en U invertida, con niveles más bajos en la etapa intermedia de la carrera, cuando las demandas laborales y familiares se acumulan, y mejora progresiva al avanzar hacia la madurez (Haar, 2013; Haar & Brougham, 2022). Su presencia no afecta a los demás coeficientes. La variable de IA generativa presenta un VIF de 1,21, cercano a 1, lo que indica que está prácticamente ortogonal al resto de regresores, facilitando la interpretación de sus coeficientes en los modelos multivariantes.

**Tabla 3.3.** Test de multicolinealidad – Factor de inflación de la varianza (VIF)

**Tabla 3.3. Test VIF – Factor de Inflación de la Varianza (N=26,247 casos completos). Fuente: EWCS 2024/25. Elaboración propia.**

Variable	VIF	Interpretación
Edad <sup>2</sup>	44.76	Mecánico (par edad/edad <sup>2</sup> )
Edad	44.25	Mecánico (par edad/edad <sup>2</sup> )
Educación alta	2.93	Aceptable (<5)
Educación media	2.65	Aceptable (<5)
Teletrabajo (z)	1.34	Aceptable (<5)
Asalariado	1.22	Aceptable (<5)
Uso de IA generativa	1.20	Aceptable (<5)
Horas semanales	1.18	Aceptable (<5)
Pyme (≤249 emp.)	1.13	Aceptable (<5)
Autonomía laboral (z)	1.12	Aceptable (<5)
Mujer	1.07	Aceptable (<5)
Intensidad laboral (z)	1.06	Aceptable (<5)

Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.

### 3.7. Variables del modelo y especificación

La especificación detallada del modelo, incluyendo la operacionalización de cada variable dependiente (D1–D5), la variable explicativa principal (tech\_genAI), los moderadores y los controles con sus escalas, N válido y justificación teórica, se presenta en las subsecciones siguientes y se implementa íntegramente en el código de análisis disponible en el Apéndice A de este trabajo, que permite la reproducción completa de todos los resultados reportados en la Sección 4.

Estructura del modelo estimado. Para cada dimensión  $WLB_k$  ( $k = D1, D2, D3, D4, D5$ ) se estima la siguiente ecuación general:  $WLB_{ki} = \alpha + \beta_1 \cdot GenAI_i + \beta_2 \cdot Moderadores_i + \beta_3 \cdot (GenAI_i \times Moderadores_i) + \gamma \cdot Controles_i + \delta_j + \varepsilon_i$  donde  $GenAI_i$  es la dummy de uso de IA generativa;  $Moderadores_i$  incluye los índices de autonomía, intensidad laboral y la dummy de teletrabajo regular;  $Controles_i$  engloba género, edad, edad<sup>2</sup>, nivel educativo, horas habituales, tamaño de empresa y condición de asalariado; y  $\delta_j$  son los efectos fijos de país ( $j = 1, \dots, 26$ , con España como referencia) junto con dummies de ocupación (ISCO-1) y sector (NACE).

La estimación se realiza de forma stepwise en tres etapas: Modelo 1 (solo controles), Modelo 2 (+ GenAI + moderadores), Modelo 3 (+ interacciones). El diseño es primariamente confirmatorio respecto a H1–H5 y exploratorio para las interacciones del Modelo 3: los términos de interacción no se derivan de hipótesis confirmatorias preregistradas, sino de expectativas de dirección teóricamente motivadas (H3a, H2a, H4a; véase §2.6), lo que requiere cautela en su interpretación y replicación. Todos los modelos utilizan OLS con errores estándar robustos HC3.

### **3.8. Pruebas de robustez y limitaciones**

Se llevaron a cabo las siguientes pruebas de robustez: (i) operacionalizaciones alternativas de las variables dependientes (ítem individual vs. índice; M3a, M3b y M3c por separado frente a M3 completo); (ii) exclusión del término de interacción para comparar con el modelo aditivo; (iii) estimación con y sin ponderaciones muestrales; (iv) errores estándar agrupados (clustered) por país como alternativa a HC3; (v) exclusión de Luxemburgo (n=512) para verificar estabilidad con muestras reducidas; (vi) inclusión de la variable permanent (contrato indefinido) en el modelo base, a pesar de su 16,1% missing, para verificar que su omisión no sesga los coeficientes principales. El patrón central, intensificación en D3 y D4, ausencia de efecto en D1 y D5, se mantiene en todas las especificaciones alternativas. La extensión a datos longitudinales y el uso de medidas de intensidad de uso de IA generativa constituyen líneas de investigación futura.

Las principales limitaciones del estudio son: (1) la naturaleza transversal y observacional de los datos impide inferencia causal; (2) la variable de IA generativa es binaria, sin información sobre intensidad, tipo o antigüedad de uso; (3) la endogeneidad potencial por selección (los trabajadores que usan IA son sistemáticamente distintos en características no observables); y (4) la auto-declaración puede introducir sesgo de deseabilidad social. Estas limitaciones se discuten en detalle en la sección de conclusiones.

## 4. Resultados

### 4.1. Presentación general de los resultados

Esta sección presenta los resultados de los modelos de regresión OLS stepwise estimados para las cinco dimensiones de conciliación vida–trabajo (WLB) definidas en la metodología. Para cada dimensión se estiman tres especificaciones: el Modelo 1 (M1), que incluye únicamente el bloque de variables de control sociodemográficas y laborales; el Modelo 2 (M2), que añade la variable principal de exposición a IA generativa y los tres moderadores organizativos (teletrabajo, autonomía e intensidad laboral); y el Modelo 3 completo (M3), que incorpora los términos de interacción entre IA generativa y cada uno de los moderadores. Con carácter previo se estiman también las interacciones de forma separada (M3a, M3b, M3c) para evaluar la robustez de cada moderador de forma individual.

Todos los modelos se estiman mediante OLS con errores estándar robustos (HC3) y controlan por efectos fijos de país (referencia: España), ocupación (ISCO-1, referencia: Profesionales, categoría 2) y sector de actividad (NACE, referencia: Administración pública). Las variables dependientes han sido invertidas siguiendo un criterio específico por dimensión: en D1 (encaje global) y D5 (predicibilidad horaria), un coeficiente positivo indica mejor WLB; en D2, D3 y D4, un coeficiente positivo indica más interferencia o desbordamiento (peor WLB). La interpretación sustantiva se reporta explícitamente en cada sub-sección. La muestra de trabajo incluye 25.138 observaciones con información completa en todas las variables del modelo.

La Tabla 4.1 ofrece una visión de conjunto de los coeficientes de IA generativa en todos los modelos y dimensiones, mientras que la Figura 4.1 los representa gráficamente con intervalos de confianza al 95%. Las Tablas 4.2 a 4.6 detallan los coeficientes completos por dimensión y la Tabla 4.7 recoge los efectos de interacción. Los hallazgos se organizan en torno a las cinco hipótesis planteadas en el marco teórico.

**Tabla 4.1.** Resultados de los modelos OLS Stepwise

Tabla 4.1. Coeficiente  $\beta$ (IA generativa) en M1, M2 y M3 completo por dimensión WLB. N=25,138. HC3. Fuente: EWCS 2024/25.

DV	R <sup>2</sup> M1	$\beta$ M2	SE M2	R <sup>2</sup> M2	$\beta$ M3full	R <sup>2</sup> M3
D1: Encaje global WLB	0.127	+0.015n.s.	0.015	0.161	-0.007n.s.	0.161
D2: Interferencia tiempo-familia	0.112	+0.054*	0.021	0.173	+0.092***	0.174
D3: Trabajo fuera de horario	0.161	+0.149***	0.022	0.223	+0.167***	0.225
D4: Interferencia por tensión	0.152	+0.092***	0.022	0.200	+0.143***	0.201
D5: Predicibilidad del horario	0.149	-0.023n.s.	0.015	0.169	-0.031n.s.	0.169

#### **4.2. D1: Encaje global vida–trabajo**

La primera dimensión analizada es el encaje global WLB, medido por la pregunta “¿Cómo encaja su vida laboral con su vida personal y familiar?” (work\_life\_balance, invertida: 4=Muy bien, 1=Nada bien). Esta variable representa la evaluación subjetiva y global que el trabajador hace de su conciliación, constituyendo la medida más directa de la hipótesis H1. Los resultados del M2 muestran que el coeficiente de IA generativa sobre el encaje global WLB no es estadísticamente significativo ( $\beta=+0,015$ ;  $SE=0,015$ ;  $p=0,319$ ). El efecto tampoco alcanza significación en el M3 completo ( $\beta=-0,007$ ;  $p=0,710$ ). En consecuencia, la hipótesis H1, que predecía una asociación positiva entre uso de IA generativa y mejor encaje WLB global, no encuentra respaldo empírico en los datos del EWCS 2024/25. Sí resultan significativos los moderadores: el teletrabajo se asocia positivamente con mejor encaje global ( $\beta=+0,021$ ;  $p<0,001$  en M2), mientras que la autonomía ( $\beta=-0,070$ ;  $p<0,001$ ) y la intensidad laboral ( $\beta=-0,126$ ;  $p<0,001$ ) muestran asociaciones negativas, indicando que los entornos de trabajo más autónomos y de mayor intensidad se asocian, paradójicamente, con peor encaje global en esta muestra. Entre los controles, las horas semanales ( $\beta=-0,015$ ;  $p<0,001$ ) y ser asalariado frente a autónomo ( $\beta=+0,123$ ;  $p<0,001$ ) son los predictores más relevantes. El modelo M2 explica un 16,1% de la varianza ( $R^2=0,161$ ). Los términos de interacción en M3 son todos no significativos ( $p>0,19$  en los tres), lo que indica que el efecto nulo de la IA sobre el encaje global no varía de forma significativa según el nivel de teletrabajo, autonomía o intensidad laboral.

**Tabla 4.2.** Regresión OLS — Encaje global WLB (D1). Efectos fijos de país, ocupación (ISCO-1) y sector (NACE)

D1: Encaje global WLB

Variable	M1	M2	M3full
IA generativa	—	+0.015 (0.015)	-0.007 (0.019)
Teletrabajo (z)	—	+0.021*** (0.005)	+0.018** (0.006)
Autonomía (z)	—	-0.072*** (0.005)	-0.070*** (0.005)
Intensidad (z)	—	-0.126*** (0.005)	-0.124*** (0.005)
IA × Teletrabajo	—	—	+0.017 (0.014)
IA × Autonomía	—	—	-0.036 (0.019)
IA × Intensidad	—	—	-0.025 (0.015)
Mujer	-0.033*** (0.010)	-0.015 (0.010)	-0.014 (0.010)
Edad	-0.015*** (0.002)	-0.016*** (0.002)	-0.016*** (0.002)
Educ. media	+0.026 (0.015)	+0.022 (0.015)	+0.021 (0.015)
Educ. alta	+0.015 (0.018)	+0.004 (0.018)	+0.004 (0.018)
Horas semanales	-0.017*** (0.000)	-0.015*** (0.000)	-0.015*** (0.000)
Pyme (≤249 emp.)	+0.009 (0.011)	-0.010 (0.010)	-0.010 (0.010)
Asalariado	+0.059*** (0.014)	+0.123*** (0.015)	+0.122*** (0.015)
R <sup>2</sup>	0.127	0.161	0.161
N	25,138	25,138	25,138

Fuente: Datos de EWCS 2024/25. Elaboración Propia

### 4.3. D2: Interferencia trabajo–familia basada en tiempo

La segunda dimensión mide la interferencia del trabajo sobre el tiempo familiar (*wlb\_timefamily*, invertida: 5=Siempre impide, 1=Nunca impide). Refleja el canal temporal de conflicto trabajo–familia de la hipótesis H2. El coeficiente de IA generativa en M2 es positivo y estadísticamente significativo ( $\beta=+0,054$ ;  $SE=0,021$ ;  $p=0,011$ ). Este resultado indica que los usuarios de IA generativa reportan con mayor frecuencia que el trabajo interfiere en su tiempo familiar, lo que va en contra de H2, que predecía menor interferencia temporal: la evidencia apunta al canal de intensificación, no al de eficiencia. La intensidad laboral es el predictor más potente de esta dimensión ( $\beta=+0,279$ ;  $p<0,001$  en M2), seguida de las horas semanales ( $\beta=+0,019$ ;  $p<0,001$ ) y de ser mujer ( $\beta=+0,102$ ;  $p<0,001$ ), reflejando la bien documentada doble carga de las trabajadoras. El R<sup>2</sup> del M2 es de 0,173. En el M3 completo, el efecto directo de la IA aumenta ( $\beta=+0,092$ ;  $p<0,001$ ). La interacción IA×Autonomía es positiva y significativa ( $\beta=+0,078$ ;  $p=0,004$ ): entre los trabajadores con mayor autonomía, la IA se asocia con mayor interferencia tiempo–familia, apoyando H2a. Este resultado puede reflejar que la autonomía amplifica la "colonización" del espacio personal cuando se combina con herramientas que eliminan fricciones de la tarea laboral.

**Tabla 4.3.** Regresión OLS — Interferencia temporal (D2)

D2: Interferencia tiempo-familia

Variable	M1	M2	M3full
IA generativa	—	+0.054* (0.021)	+0.092*** (0.028)
Teletrabajo (z)	—	+0.039*** (0.008)	+0.042*** (0.008)
Autonomía (z)	—	+0.042*** (0.007)	+0.037*** (0.007)
Intensidad (z)	—	+0.279*** (0.007)	+0.276*** (0.007)
IA × Teletrabajo	—	—	-0.018 (0.020)
IA × Autonomía	—	—	+0.078** (0.027)
IA × Intensidad	—	—	+0.032 (0.022)
Mujer	+0.141*** (0.015)	+0.102*** (0.014)	+0.101*** (0.014)
Edad	+0.039*** (0.003)	+0.038*** (0.003)	+0.038*** (0.003)
Educ. media	-0.050* (0.023)	-0.054* (0.022)	-0.054* (0.022)
Educ. alta	+0.038 (0.026)	+0.008 (0.026)	+0.008 (0.026)
Horas semanales	+0.023*** (0.001)	+0.019*** (0.001)	+0.019*** (0.001)
Pyme (≤249 emp.)	-0.038* (0.016)	+0.009 (0.015)	+0.009 (0.015)
Asalariado	-0.145*** (0.020)	-0.169*** (0.020)	-0.168*** (0.020)
R <sup>2</sup>	0.112	0.173	0.174
N	25,138	25,138	25,138

Fuente: EWCS 2024/25. Elaboración propia.

#### 4.4. D3: Trabajo fuera del horario laboral

La tercera dimensión captura la frecuencia con la que el trabajador dedica tiempo libre al trabajo (freetime\_work, invertida: 5=Cada día, 1=Nunca). Esta variable se utiliza en lugar de contact\_out\_wh, que presenta un 16,8% de valores ausentes; su uso habría reducido la muestra y generado sesgo de selección. Ambas variables capturan la misma dimensión de desbordamiento temporal (H3). Un coeficiente positivo indica mayor frecuencia de trabajo en el tiempo libre, es decir, peor conciliación. En el M2, el coeficiente de IA generativa es positivo y altamente significativo ( $\beta=+0,149$ ;  $SE=0,022$ ;  $p<0,001$ ). Este resultado indica que los usuarios de IA generativa trabajan más frecuentemente en su tiempo libre, presentando peor conciliación temporal, lo que es coherente con H3. Los moderadores son relevantes: el teletrabajo amplifica el trabajo fuera de horario ( $\beta=+0,203$ ;  $p<0,001$ ), confirmando el efecto "always-on". La intensidad laboral tiene el mayor efecto en esta dimensión ( $\beta=+0,179$ ;  $p<0,001$ ). El modelo M2 explica el 22,3% de la varianza, el mayor R<sup>2</sup> entre las cinco dimensiones. En el M3 completo, el efecto directo de la IA se mantiene significativo y aumenta ( $\beta=+0,167$ ;  $p<0,001$ ). Destaca la interacción IA×Intensidad ( $\beta=+0,128$ ;  $p<0,001$ ): entre los trabajadores de mayor intensidad laboral, el uso de IA agrava especialmente el trabajo en tiempo libre, apoyando H3a. La interacción IA×Teletrabajo es negativa y significativa ( $\beta=-0,054$ ;  $p=0,004$ ): el teletrabajo mitiga parcialmente el desbordamiento, aunque no lo anula.

**Tabla 4.4.** Regresión OLS — Trabajo fuera de horario (D3)

D3: Trabajo fuera de horario

Variable	M1	M2	M3full
IA generativa	—	+0.149*** (0.022)	+0.167*** (0.026)
Teletrabajo (z)	—	+0.195*** (0.008)	+0.203*** (0.009)
Autonomía (z)	—	-0.034*** (0.006)	-0.034*** (0.006)
Intensidad (z)	—	+0.192*** (0.006)	+0.179*** (0.006)
IA × Teletrabajo	—	—	-0.054** (0.021)
IA × Autonomía	—	—	+0.007 (0.026)
IA × Intensidad	—	—	+0.128*** (0.022)
Mujer	+0.011 (0.014)	-0.022 (0.013)	-0.024 (0.013)
Edad	+0.009** (0.003)	+0.007* (0.003)	+0.007* (0.003)
Educ. media	+0.018 (0.019)	+0.005 (0.019)	+0.005 (0.019)
Educ. alta	+0.158*** (0.023)	+0.069** (0.022)	+0.068** (0.022)
Horas semanales	+0.018*** (0.001)	+0.015*** (0.001)	+0.015*** (0.001)
Pyme (≤249 emp.)	-0.010 (0.014)	+0.038** (0.013)	+0.038** (0.013)
Asalariado	-0.484*** (0.022)	-0.361*** (0.022)	-0.359*** (0.022)
R <sup>2</sup>	0.161	0.223	0.225
N	25,138	25,138	25,138

Fuente: EWCS 2024/25. Elaboración propia.

#### 4.5. D4: Interferencia trabajo–familia basada en tensión

La cuarta dimensión mide la interferencia cognitiva y emocional del trabajo sobre la vida personal, a través de la preocupación fuera del horario laboral (wlb\_worry, invertida: 5=Siempre, 1=Nunca). Esta dimensión captura el canal de tensión (strain-based) del conflicto trabajo–vida, central en la hipótesis H4. El coeficiente de IA generativa en M2 es positivo y altamente significativo ( $\beta=+0,092$ ;  $SE=0,022$ ;  $p<0,001$ ). Dado que el signo positivo en una escala invertida indica mayor interferencia, este resultado confirma la hipótesis H4: los usuarios de IA generativa reportan mayor preocupación laboral fuera del horario de trabajo, sugiriendo que la tecnología amplifica la tensión cognitiva en lugar de aliviarla. El efecto se mantiene robusto en el M3 completo ( $\beta=+0,143$ ;  $p<0,001$ ). La intensidad laboral vuelve a ser el predictor más fuerte ( $\beta=+0,234$ ;  $p<0,001$ ). Ser mujer también se asocia positivamente con mayor tensión ( $\beta=+0,093$ ;  $p<0,001$ ). El R<sup>2</sup> del M2 es de 0,200. Al igual que en D2, la interacción IA×Autonomía resulta positiva y significativa en M3 ( $\beta=+0,074$ ;  $p=0,004$ ): la autonomía amplifica el efecto de la IA sobre la tensión cognitiva, posiblemente porque los trabajadores con mayor control sobre sus tareas internalizan de forma más intensa las demandas generadas o visibilizadas por el uso de IA. Este patrón es consistente con el marco JD–R y con la lógica del "doble efecto" tecnológico descrito en la sección 2.6.

**Tabla 4.5.** Regresión OLS — Interferencia por tensión (D4)

**D4: Interferencia por tensión**

Variable	M1	M2	M3full
IA generativa	—	+0.092*** (0.022)	+0.143*** (0.029)
Teletrabajo (z)	—	+0.111*** (0.009)	+0.117*** (0.009)
Autonomía (z)	—	-0.048*** (0.007)	-0.053*** (0.008)
Intensidad (z)	—	+0.237*** (0.007)	+0.234*** (0.008)
IA × Teletrabajo	—	—	-0.037 (0.021)
IA × Autonomía	—	—	+0.074** (0.028)
IA × Intensidad	—	—	+0.025 (0.023)
Mujer	+0.128*** (0.015)	+0.093*** (0.015)	+0.093*** (0.015)
Edad	+0.032*** (0.003)	+0.029*** (0.003)	+0.030*** (0.003)
Educ. media	-0.007 (0.024)	-0.022 (0.023)	-0.022 (0.023)
Educ. alta	+0.130*** (0.027)	+0.062* (0.027)	+0.061* (0.027)
Horas semanales	+0.015*** (0.001)	+0.011*** (0.001)	+0.011*** (0.001)
Pyme (≤249 emp.)	-0.027 (0.016)	+0.017 (0.015)	+0.017 (0.015)
Asalariado	-0.486*** (0.022)	-0.412*** (0.022)	-0.410*** (0.022)
R <sup>2</sup>	0.152	0.200	0.201
N	25,138	25,138	25,138

Fuente: EWCS 2024/25. Elaboración propia.

#### 4.6. D5: Facilitadores organizativos – Predicibilidad del horario

La quinta dimensión mide la predicibilidad del horario de trabajo por parte del empleador (emp\_wt\_predict, invertida: 3=Siempre predecible, 1=No predecible). Captura en qué medida la organización proporciona condiciones que faciliten la conciliación, en línea con la hipótesis H5. El coeficiente de IA generativa en M2 no es significativo ( $\beta=-0,023$ ;  $SE=0,016$ ;  $p=0,137$ ), ni tampoco en el M3 completo ( $\beta=-0,020$ ;  $p=0,317$ ). La hipótesis H5, que predecía una asociación positiva entre uso de IA y mejores facilitadores organizativos, no encuentra respaldo. El uso de IA generativa no parece estar acompañado, en la muestra, de una mayor predicibilidad horaria por parte del empleador. Esta dimensión está dominada por la condición contractual: los asalariados reportan predicibilidad horaria sistemáticamente mayor que los autónomos ( $\beta=+0,541$ ;  $p<0,001$ ), y los trabajadores en pymes también tienen menor predicibilidad ( $\beta=-0,068$ ;  $p<0,001$ ). El teletrabajo se asocia con menor predicibilidad ( $\beta=-0,101$ ;  $p<0,001$ ), consistente con la idea de que el trabajo remoto implica horarios menos estructurados. El R<sup>2</sup> del M2 es de 0,169. La única interacción significativa en D5 es IA×Teletrabajo ( $\beta=+0,031$ ;  $p=0,031$  en M3): entre los teletrabajadores, el uso de IA generativa se asocia con algo mayor predicibilidad horaria, lo que podría reflejar que las herramientas de IA facilitan la gestión autónoma del tiempo en contextos de trabajo remoto, aunque el efecto es modesto.

**Tabla 4.6.** Regresión OLS — Predicibilidad del horario (D5)

D5: Predicibilidad del horario

Variable	M1	M2	M3full
IA generativa	—	-0.023 (0.015)	-0.031 (0.019)
Teletrabajo (z)	—	-0.097*** (0.006)	-0.101*** (0.006)
Autonomía (z)	—	+0.012* (0.005)	+0.011* (0.005)
Intensidad (z)	—	-0.071*** (0.005)	-0.069*** (0.005)
IA × Teletrabajo	—	—	+0.025 (0.014)
IA × Autonomía	—	—	+0.019 (0.018)
IA × Intensidad	—	—	-0.019 (0.016)
Mujer	+0.083*** (0.010)	+0.097*** (0.010)	+0.098*** (0.010)
Edad	+0.024*** (0.002)	+0.025*** (0.002)	+0.025*** (0.002)
Educ. media	+0.001 (0.016)	+0.006 (0.016)	+0.006 (0.016)
Educ. alta	-0.006 (0.018)	+0.031 (0.018)	+0.032 (0.018)
Horas semanales	-0.003*** (0.001)	-0.002** (0.001)	-0.002** (0.001)
Pyme (≤249 emp.)	-0.049*** (0.010)	-0.068*** (0.010)	-0.068*** (0.010)
Asalariado	+0.602*** (0.016)	+0.541*** (0.016)	+0.541*** (0.016)
R <sup>2</sup>	0.149	0.169	0.169
N	25,138	25,138	25,138

Fuente: EWCS 2024/25. Elaboración propia.

#### 4.7. Efectos moderadores: modelos de interacción

La Tabla 4.7 reúne los efectos de interacción en todas las dimensiones y especificaciones (M3a–M3c y M3 completo), facilitando la comparación transversal. La Figura 4.1 representa gráficamente los efectos directos e interacciones con intervalos de confianza al 95%.

**Tabla 4.7.** Efectos de interacción IA x moderadores

Tabla 4.7. Efectos de interacción IA×moderadores (M3 completo). HC3. N=25,138. \* p<0,05 \*\* p<0,01 \*\*\* p<0,001.

DV	×Teletrabajo	×Autonomía	×Intensidad
D1: Encaje global WLB	+0.017n.s.	-0.036n.s.	-0.025n.s.
D2: Interferencia tiempo-familia	-0.018n.s.	+0.078**	+0.032n.s.
D3: Trabajo fuera de horario	-0.054**	+0.007n.s.	+0.128***
D4: Interferencia por tensión	-0.037n.s.	+0.074**	+0.025n.s.
D5: Predicibilidad del horario	+0.025n.s.	+0.019n.s.	-0.019n.s.


Fuente: EWCS 2024/25. Elaboración propia.

Los resultados de los modelos de interacción revelan dos patrones moderadores consistentes a través de las dimensiones. En primer lugar, la intensidad laboral actúa como amplificador del efecto de la IA sobre el desbordamiento temporal (D3:  $\beta=+0,128$ ;  $p<0,001$ ): en entornos de alta presión, la IA generativa agrava la frecuencia de trabajo en tiempo libre. Este patrón es

coherente con el mecanismo de intensificación del modelo JD–R y apoya la hipótesis H3a. En segundo lugar, la autonomía laboral amplifica la interferencia cognitiva y temporal: en D2 ( $\beta=+0,078$ ;  $p=0,004$ ) y D4 ( $\beta=+0,075$ ;  $p=0,004$ ), los trabajadores con alta autonomía que usan IA reportan mayor interferencia. Este resultado sugiere que la autonomía, lejos de amortiguar el impacto de la IA, puede amplificar la "colonización" del espacio personal cuando la tecnología elimina las fricciones naturales de la tarea, apoyando H2a y H4a. El teletrabajo exhibe efectos moderadores distintos según la dimensión: mitiga el desbordamiento temporal (D3:  $\beta=-0,054$ ;  $p=0,004$ ) pero no muestra efectos significativos sobre la tensión cognitiva (D2, D4), ni sobre la predicibilidad horaria (D5:  $\beta=+0,025$ ;  $p=0,077$ ). Este patrón dissociado sugiere que el teletrabajo opera principalmente sobre los límites temporales, reduciendo parcialmente el desbordamiento asociado a la IA, pero no sobre los mecanismos de tensión cognitiva.

**Figura 4.1.** Coeficientes de IA generativa y términos de interacción

**Figura 4.1. Coeficientes de IA generativa y términos de interacción**



Fuente: EWCS 2024/25. Elaboración propia.

#### 4.8. Síntesis: contraste de hipótesis

La Tabla 4.8 sintetiza el grado de respaldo empírico obtenido para cada una de las cinco hipótesis del estudio a partir de los resultados de los modelos OLS stepwise.

**Tabla 4.8.** Síntesis: contraste de hipótesis

<b>H1 (+)</b>	IA gen. → mejor encaje WLB global	D1	$\beta=+0,015$ ; $p=0,319$ (n.s.)	<b>No respaldada</b>
<b>H2 (+)</b>	IA gen. → menos interferencia temporal	D2	$\beta=+0,054^*$ ; $p=0,011$	<b>No respaldada (efecto contrario)</b>
<b>H3 (-)</b>	IA gen. → más trabajo en tiempo libre	D3	$\beta=+0,149^{***}$ ; $p<0,001$	<b>Respaldada</b>
<b>H4 (-)</b>	IA gen. → más interferencia por tensión	D4	$\beta=+0,092^{***}$ ; $p<0,001$	<b>Respaldada</b>
<b>H5 (+)</b>	IA gen. → más facilitadores organizativos	D5	$\beta=-0,023$ ; $p=0,137$ (n.s.)	<b>No respaldada</b>

Nota: En D3 y D4 el coeficiente positivo con escala invertida indica mayor trabajo en tiempo libre (D3) y mayor tensión (D4), respectivamente, es decir, peor WLB, consistente con H3 y H4. En D2 el coeficiente también es positivo (peor WLB), contrario a H2.

## 5. Discusión

Este trabajo ha examinado la asociación entre el uso de IA generativa en el trabajo y cinco dimensiones de conciliación vida–trabajo (WLB) en una muestra representativa de 25.138 trabajadores de los 27 Estados miembros de la UE, utilizando microdatos de la EWCS 2024/25. El análisis combina estadísticos descriptivos, correlaciones de Spearman y modelos OLS stepwise con errores estándar robustos HC3, controles sociodemográficos y laborales exhaustivos, efectos fijos de país, ocupación y sector, y términos de interacción con tres moderadores organizativos. Los resultados permiten extraer conclusiones matizadas sobre los canales a través de los cuales la IA generativa reconfigura la experiencia laboral y su compatibilidad con la vida personal, con implicaciones directas para la gestión de personas y la política pública europea.

El hallazgo central del estudio es que, en la muestra analizada, el uso de IA generativa no se asocia con una mejora neta de la conciliación: ninguna de las cinco dimensiones muestra un efecto positivo significativo atribuible a la IA. Por el contrario, tres dimensiones presentan asociaciones negativas significativas, mayor trabajo en tiempo libre: los trabajadores que usan IA experimentan mayor interferencia del trabajo sobre su tiempo familiar, trabajan más frecuentemente en su tiempo libre y reportan mayor tensión cognitiva fuera del horario laboral. La percepción global de conciliación y la predicibilidad horaria, en cambio, no muestran diferencias estadísticamente significativas entre usuarios y no usuarios. Este patrón es consistente con el predominio del canal de intensificación y conectividad sobre el canal de eficiencia postulados en el marco teórico (Lee, 2024; Vyas, 2022; Chen & Li, 2024), y constituye el hilo conductor de toda la discusión que sigue.

Cabía esperar que el uso de IA generativa se asociara con una mejor percepción global del equilibrio entre trabajo y vida personal, a través del canal de eficiencia. Los datos no respaldan esta predicción: el coeficiente de IA en D1 es positivo, pero no alcanza significación estadística, y se anula completamente al incluir las interacciones. La ausencia de efecto en D1 es llamativa, porque esta dimensión capta precisamente la evaluación subjetiva global que el trabajador hace de su conciliación; si la IA generativa liberase recursos cognitivos y temporales significativos, debería reflejarse en esta medida holística. El resultado nulo sugiere que, a nivel de percepción global, los posibles beneficios de eficiencia que aporta la IA quedan

compensados, o incluso superados, por los efectos de intensificación que se manifiestan en las otras dimensiones. En términos del marco JD–R, la IA generativa no actuaría como un recurso neto: aunque puede aumentar la capacidad de procesamiento de tareas, también eleva las demandas percibidas o las expectativas sobre el rendimiento, de modo que el balance subjetivo de conciliación no mejora (Haar & Brougham, 2022; Fan et al., 2021).

El hallazgo más robusto del estudio es que los usuarios de IA generativa trabajan significativamente más en su tiempo libre que quienes no la usan, y esta asociación se mantiene con claridad en todos los modelos estimados, incluso controlando por ocupación, sector, país, horas trabajadas y otras características individuales y laborales. Este resultado es interpretable en clave de conectividad y aceleración: las herramientas de IA generativa reducen las fricciones de la tarea (redacción, búsqueda, síntesis) y, al hacerlo, pueden hacer que completar tareas fuera del horario resulte más fácil y menos costoso, bajando el umbral de activación para prolongar la jornada de forma informal. En línea con la advertencia de Vyas (2022) sobre el "always-on" del teletrabajo digital, los datos sugieren que la IA generativa amplifica el mismo mecanismo: la flexibilidad tecnológica no viene acompañada automáticamente de normas organizativas que protejan el tiempo personal.

El papel moderador de la intensidad laboral refuerza esta lectura. El análisis muestra que, en entornos de alta presión temporal, el efecto negativo de la IA sobre el tiempo libre es especialmente pronunciado: cuando las demandas de trabajo ya son elevadas, la IA actúa como amplificador de carga, no como alivio, porque los ritmos acelerados por la tecnología generan más trabajo del que el trabajador puede absorber en la jornada regular. La interacción entre IA y teletrabajo, negativa y significativa sobre el trabajo en tiempo libre, añade un matiz relevante: el teletrabajo reduce parcialmente el desbordamiento asociado a la IA (Kelliher & Anderson, 2010), posiblemente porque los teletrabajadores ya han construido mecanismos de gestión de límites o disponen de mayor flexibilidad estructural para reorganizar su tiempo. Con todo, este efecto mitigador no anula el efecto directo, que permanece altamente significativo.

Se esperaba que la IA generativa redujera la interferencia del trabajo sobre el tiempo familiar, al liberar capacidad cognitiva y mejorar la gestión del tiempo dentro de la jornada. Los

resultados apuntan, sin embargo, en dirección contraria: los usuarios de IA reportan con mayor frecuencia que el trabajo interfiere en su tiempo familiar, tanto en los modelos más sencillos como en los más completos. Este resultado es el más sorprendente desde la perspectiva del canal de eficiencia, y puede interpretarse de varias formas complementarias. En primer lugar, si la IA generativa facilita la realización de tareas en cualquier momento y lugar, puede hacer que el trabajo filtre hacia el espacio doméstico y familiar no solo en tiempo libre genérico, sino también de forma específica en momentos dedicados a la familia. En segundo lugar, es posible que el aumento de la carga de trabajo generada o visibilizada por la IA supere las ganancias de eficiencia, de modo que el saldo neto sobre el tiempo familiar sea negativo. En cualquier caso, el canal de intensificación prevalece también en esta dimensión.

La relación entre autonomía laboral e interferencia temporal añade un hallazgo relevante: los trabajadores con mayor autonomía que usan IA presentan aún mayor interferencia sobre su tiempo familiar. Este resultado contraintuitivo puede reflejar una dinámica de "colonización" del espacio personal: cuando el trabajador dispone de mayor discrecionalidad sobre cómo y cuándo realiza sus tareas, la IA, al reducir la fricción cognitiva de las mismas, puede facilitar que las extienda más allá de los horarios laborales sin que exista una presión jerárquica explícita para ello. En términos del marco COR, la autonomía que debería actuar como recurso protector puede, en combinación con herramientas tecnológicas que eliminan costes de transacción de la tarea, convertirse en un facilitador del desbordamiento (Hobfoll, 1989; Haar & Brougham, 2022).

Los resultados confirman que los usuarios de IA generativa reportan significativamente mayor preocupación laboral fuera del horario de trabajo, tanto en los análisis más básicos como en los más complejos, y este efecto se amplía cuando se tiene en cuenta el contexto organizativo de cada trabajador. Este hallazgo conecta directamente con la idea del "doble efecto" de Chen & Li (2024): incluso si la IA mejora la capacidad de realizar tareas, puede generar al mismo tiempo mayor carga mental, bien porque eleva las expectativas de productividad (el llamado estrés por reemplazo o por aceleración), bien porque la disponibilidad continua de herramientas laborales mantiene la mente anclada al trabajo incluso durante el tiempo personal (Lee, 2024; Chen & Li, 2024).

El patrón observado en la interferencia temporal se replica con la tensión cognitiva: la autonomía laboral amplifica la tensión cognitiva asociada al uso de IA, probablemente porque los trabajadores con mayor control sobre sus tareas internalizan más intensamente las demandas generadas por la tecnología. Este resultado tiene consecuencias prácticas relevantes: las intervenciones que aumentan la autonomía sin proporcionar normas claras de límites digitales pueden, en entornos de alta adopción de IA, generar más tensión en lugar de menos. La literatura sobre apoyo organizativo a la WLB apunta en la misma dirección: la disponibilidad formal de recursos no implica automáticamente su uso efectivo si no existe un entorno normativo que legitime la desconexión (Fan et al., 2021; Haar & Harris, 2025).

La predictibilidad del horario está gobernada principalmente por variables estructurales (condición de asalariado frente a autónomo, tamaño de empresa, sector) y la adopción tecnológica per se no parece modificarla. Este resultado sugiere que las características organizativas que permiten conciliar, especialmente la estructuración del tiempo de trabajo, responden a lógicas institucionales y contractuales que la IA generativa no altera directamente. La interacción con el teletrabajo apunta marginalmente a que, entre quienes trabajan a distancia, la IA podría asociarse con algo mayor predicibilidad horaria, pero la evidencia es insuficiente para concluirlo. Este resultado no cambia la conclusión general: el uso de IA generativa no mejora de forma significativa la predicibilidad del horario laboral.

Una lectura transversal de los efectos moderadores revela tres patrones que merecen atención especial. Primero, la intensidad laboral es el amplificador más potente del impacto negativo de la IA: en todas las dimensiones de WLB, la intensidad se asocia directamente con peores resultados (efectos directos de la intensidad sobre todas las dimensiones analizadas) y su interacción con la IA generativa agrava especialmente el desbordamiento hacia el tiempo libre. El mensaje es claro: implantar IA generativa en entornos de alta presión, sin gestionar la carga de trabajo, no solo no mejora la conciliación, sino que la deteriora. Segundo, la autonomía actúa de forma paradójica: aunque es un recurso positivo para la conciliación en algunas dimensiones, su interacción con la IA genera mayor interferencia temporal y cognitiva. Este hallazgo sugiere que la autonomía sin límites digitales explícitos puede convertirse en un facilitador no intencional del desbordamiento. Tercero, el teletrabajo exhibe un patrón disociado: mitiga el desbordamiento hacia el tiempo libre pero no la tensión cognitiva. Esto es

coherente con la idea de que el teletrabajo opera principalmente sobre la gestión de límites espacio-temporales, permite reorganizar el tiempo, pero no sobre los mecanismos afectivos y cognitivos del conflicto trabajo–vida (Vyas, 2022).

Los resultados deben interpretarse también a la luz de la heterogeneidad institucional documentada en el análisis descriptivo. Los países Nórdicos presentan tasas de adopción de IA generativa significativamente superiores a la media (>20%) y, simultáneamente, los mejores resultados de conciliación en el conjunto de clusters. Esta correlación positiva bruta no contradice los resultados multivariantes, ya que los efectos fijos de país absorben las diferencias institucionales estructurales. La coexistencia de alta adopción de IA y buena WLB en los países Nórdicos puede reflejar que, cuando la adopción se produce en contextos con normas sólidas de desconexión, codecisión y negociación colectiva robusta, los efectos negativos de la intensificación pueden mitigarse. En cambio, en los clusters Mediterráneo y de Europa del Este, con menor densidad sindical, mayor peso de pymes y marcos de conciliación menos formalizados, la baja adopción actual puede esconder riesgos futuros considerables si la adopción crece sin que se desarrollen paralelamente los mecanismos de protección. Esto es especialmente relevante dado que el AI Act europeo impondrá en los próximos años obligaciones crecientes que afectarán también a las herramientas de IA generativa de propósito general (GPAI), acelerando potencialmente la difusión en todos los clusters.

Varias limitaciones condicionan el alcance de las conclusiones anteriores. La más importante es la naturaleza transversal y observacional de los datos: los coeficientes estimados capturan asociaciones netas, controladas por un amplio conjunto de covariables, pero no permiten inferencia causal en sentido estricto. En particular, es posible que la adopción de IA generativa correlacione con características no observables de la organización, cultura de alta exigencia, ritmos de trabajo acelerados, perfiles de alta dedicación, que expliquen parcialmente los patrones observados. Dicho de otro modo, no podemos descartar que sean las organizaciones con mayor presión las que adoptan antes la IA, y no que la IA cause la presión. Para abordar esta limitación sería necesario disponer de datos de panel, observando a los mismos trabajadores antes y después de la adopción, o de diseños cuasiexperimentales con variación exógena en la exposición.

Una segunda limitación es el carácter binario de la variable de IA generativa (usa/no usa), que impide distinguir la intensidad de uso, el tipo de herramienta, la antigüedad de la adopción o el grado de integración en los procesos de trabajo. Es plausible que los efectos sean no lineales: trabajadores con uso muy intensivo de IA podrían mostrar patrones distintos a los de usuarios ocasionales. Futuras ediciones de la EWCS, o encuestas específicas sobre IA laboral, deberían incorporar medidas de intensidad y tipología de uso para capturar esta heterogeneidad. En tercer lugar, la auto-declaración de todas las variables introduce potencial sesgo de respuesta: tanto la declaración del uso de IA como la evaluación de la conciliación dependen de la percepción subjetiva del encuestado, lo que puede introducir correlaciones espurias si ciertos perfiles tienden sistemáticamente a valorarse más o menos favorablemente en ambas dimensiones.

Los hallazgos tienen implicaciones directas para las organizaciones que están gestionando la introducción de IA generativa en sus procesos. El primer mensaje es que la implantación tecnológica no puede desacoplarse de la gestión de la carga de trabajo: los resultados muestran que la IA amplifica especialmente el desbordamiento temporal en entornos de alta intensidad, lo que sugiere que las organizaciones deben acompañar la adopción de IA con una revisión explícita de las expectativas de rendimiento y los volúmenes de trabajo. Introducir herramientas que aumentan la capacidad de producción sin ajustar el nivel de demandas puede generar una espiral de intensificación que deteriore la conciliación y, a medio plazo, el bienestar y la retención del talento.

El segundo mensaje para las organizaciones es que la autonomía necesita acompañarse de normas claras de desconexión digital. El efecto moderador negativo de la autonomía sobre las dimensiones de tensión sugiere que los modelos de trabajo flexible, que son precisamente los que suelen acompañar la adopción de IA, pueden, sin guardianes normativos explícitos, facilitar la “colonización” del tiempo personal. Las organizaciones deberían diseñar políticas de uso responsable de IA que incluyan expectativas explícitas sobre disponibilidad, protocolos de no respuesta fuera de horario y revisiones periódicas de la carga de trabajo en los equipos con mayor uso de IA. En este sentido, la evidencia es coherente con la literatura sobre apoyo organizativo a la WLB: la diferencia no está en si la organización dispone formalmente de

políticas de conciliación, sino en si el entorno normativo legitima activamente su uso (Fan et al., 2021; Haar & Harris, 2025).

En tercer lugar, el teletrabajo emerge como un moderador con potencial protector parcial: mitiga el desbordamiento temporal asociado a la IA , aunque no la tensión cognitiva. Las organizaciones que combinan teletrabajo regular con adopción de IA generativa deberían aprovechar esta complementariedad para estructurar mejor los límites del tiempo de trabajo, pero no asumir que el teletrabajo por sí solo protege frente a la preocupación y el agotamiento cognitivo: estos requieren intervenciones adicionales orientadas al diseño de la tarea y a la cultura de desconexión. Los programas de bienestar digital, que abordan el manejo de notificaciones, la gestión atencional y la recuperación post-jornada, resultan especialmente relevantes en este contexto.

Desde la perspectiva de la política pública europea, los resultados de este trabajo aportan evidencia empírica que apoya el refuerzo de dos marcos regulatorios actualmente en construcción. El primero es el derecho a la desconexión: el Parlamento Europeo pidió una directiva en 2021 y la Comisión Europea consultó a los interlocutores sociales sobre teletrabajo justo y desconexión en 2024. Los datos de la EWCS 2024/25 muestran que los usuarios de IA generativa trabajan significativamente más en su tiempo libre (con una diferencia estadísticamente significativa y robusta tras controlar por horas semanales, sector, ocupación y país), lo que proporciona justificación empírica para establecer salvaguardas legales específicas vinculadas al uso de herramientas de IA en el trabajo. Una directiva de desconexión debería contemplar explícitamente el uso de IA generativa como factor que eleva el riesgo de desbordamiento digital, y exigir a las organizaciones que implanten planes de uso responsable de IA junto con protocolos de disponibilidad y recuperación.

El segundo marco es el AI Act (Reglamento UE 2024/1689), en vigor desde agosto de 2024, cuyo calendario de aplicación introduce obligaciones progresivas para los sistemas de IA de propósito general (GPAI) desde agosto de 2025. Los resultados de este trabajo sugieren que la evaluación de riesgos que el AI Act exige a los proveedores y desplegados debería incorporar explícitamente los impactos sobre las condiciones de trabajo y la WLB de las personas

empleadas. Actualmente, el AI Act clasifica los sistemas de IA en el lugar de trabajo como de alto riesgo cuando se utilizan para gestión del rendimiento o toma de decisiones sobre el empleo, pero no aborda de forma específica los sistemas de apoyo a tareas de uso genérico, como los asistentes de IA generativa, que, según este estudio, también impactan negativamente en la conciliación. Una extensión razonable del marco regulatorio sería exigir evaluaciones de impacto en WLB como parte de los requisitos de transparencia para los sistemas GPAI desplegados en contextos laborales.

La heterogeneidad institucional observada entre clusters de países añade una dimensión adicional para la política pública: los marcos de protección existentes parecen marcar la diferencia. Los países Nórdicos, con codecisión, alta densidad sindical y normas robustas de tiempo de trabajo (Green & Mostafa, 2012), presentan mayor adopción de IA y mejor WLB simultáneamente; los clusters Mediterráneo y de Europa del Este, con marcos institucionales más débiles, podrían ser especialmente vulnerables a un escenario de intensificación acelerada conforme la adopción de IA aumente. Desde el diseño de la política europea, esto apunta a la necesidad de un enfoque que no se limite a facilitar la adopción tecnológica, sino que invierta simultáneamente en el fortalecimiento de los marcos de negociación colectiva, los mecanismos de representación de los trabajadores en decisiones sobre IA, reconocidos en el AI Act como derechos de información y consulta, y las políticas de calidad del empleo en el marco de la Agenda de Trabajo Decente (OIT, ODS 8).

En definitiva, los resultados de este estudio ofrecen una imagen matizada pero preocupante del impacto de la IA generativa sobre la conciliación: no hay evidencia de que mejore el equilibrio percibido entre trabajo y vida personal, y sí hay evidencia de que agrava el desbordamiento del trabajo hacia el tiempo libre, la interferencia sobre el tiempo familiar y la tensión cognitiva fuera del horario. La transformación tecnológica del trabajo no es inevitable en sus efectos: las condiciones organizativas e institucionales, intensidad laboral, autonomía, teletrabajo, normas de desconexión, marcos de negociación colectiva, modulan significativamente su impacto. La IA generativa puede ser un recurso extraordinario de productividad, pero convertirla también en un recurso para la conciliación requiere decisiones organizativas y regulatorias deliberadas que, a día de hoy, siguen pendientes en buena parte del mercado laboral europeo.

## **6. Recomendaciones**

Las secciones anteriores han mostrado que la IA generativa se asocia consistentemente con mayor desbordamiento del trabajo hacia el tiempo libre, mayor interferencia sobre el tiempo familiar y mayor tensión cognitiva fuera del horario laboral, sin que se observe ningún efecto positivo neto sobre la conciliación. Estos resultados no son una consecuencia inevitable de la tecnología: el análisis de moderadores demuestra que el impacto depende de cómo se gestiona la introducción de la IA y de qué marcos institucionales rodean esa adopción. Las recomendaciones que siguen se derivan directamente de la evidencia empírica y se dirigen a dos actores distintos: en primer lugar, las organizaciones y responsables de RRHH que estén gestionando la adopción de IA generativa en sus equipos; en segundo lugar, los responsables de política pública a nivel europeo y nacional que trabajan en los marcos regulatorios que condicionan esta transición. Cada recomendación indica el fundamento empírico que la sustenta, el actor principal al que se dirige y un horizonte temporal orientativo.

### **6.1. Recomendaciones para organizaciones y responsables de RRHH**

Las siguientes recomendaciones se dirigen a las organizaciones, en particular a sus áreas de RRHH, transformación digital y dirección general, que estén desplegando o planificando desplegar herramientas de IA generativa. Están ordenadas por prioridad, empezando por las que responden a los hallazgos más robustos del estudio.

Rec. O1. Realizar una auditoría de carga de trabajo antes y después de la implantación de IA. El hallazgo más robusto del estudio es que la IA generativa agrava el desbordamiento temporal de forma especialmente intensa en entornos de alta intensidad laboral: la interacción entre uso de IA e intensidad laboral es la más potente de todo el análisis: en los equipos con mayor presión de trabajo, el efecto negativo de la IA sobre la conciliación es especialmente pronunciado. Antes de desplegar herramientas de IA generativa, las organizaciones deben medir la carga de trabajo real de los equipos afectados y establecer un punto de referencia. Tras la implantación, esa misma carga debe revisarse con carácter periódico (trimestral o semestral). Si la adopción de IA libera tiempo, ese tiempo debe redistribuirse explícitamente (reducción de tareas, menos reuniones, proyectos más ambiciosos) en lugar de rellenarse automáticamente con nueva carga. Esta es la intervención preventiva más importante que puede hacer una organización para evitar la espiral de intensificación documentada en este estudio. Horizonte: inmediato (antes del despliegue).

Rec. O2. Diseñar y comunicar una política explícita de desconexión digital vinculada al uso de IA. Los datos muestran que los usuarios de IA trabajan significativamente más en su tiempo libre, y que la autonomía laboral amplifica adicionalmente la interferencia temporal y la tensión cognitiva cuando se combina con IA generativa: quienes tienen mayor control sobre su trabajo presentan peores resultados en ambas dimensiones al usar estas herramientas. Esto indica que los modelos de trabajo flexible que acompañan la adopción de IA requieren normas explícitas que protejan el tiempo personal. La política debe incluir: (i) ventanas horarias de disponibilidad esperada, con franjas de desconexión garantizada; (ii) protocolo de no-respuesta fuera de horario que se aplique también a solicitudes generadas o facilitadas por herramientas de IA; (iii) norma de no expectativa de respuesta instantánea ante mensajes o tareas asistidos por IA; y (iv) revisión anual de la política con participación de los equipos. La literatura es clara: la disponibilidad formal no basta; lo que marca la diferencia es que la cultura organizativa legitime activamente su uso (Fan et al., 2021; Haar & Harris, 2025). Horizonte: corto plazo (primeros 3 meses tras el despliegue).

Rec. O3. Integrar formación en gestión de límites digitales en los programas de onboarding de IA. La reducción de la fricción cognitiva que produce la IA generativa, redactar, buscar, sintetizar se vuelve instantáneo, baja el umbral para trabajar en tiempo personal, un mecanismo que opera incluso sin presión jerárquica explícita. Los programas de adopción de IA deben incorporar, junto a la formación técnica sobre las herramientas, contenidos sobre gestión atencional y de límites: cómo configurar notificaciones, cómo establecer rutinas de cierre de jornada, cómo reconocer la proliferación de tareas asistidas por IA como una señal de alerta. Este tipo de formación, centrada en el trabajador individual y no solo en la organización, tiene evidencia creciente de efectividad en contextos de trabajo digital intensivo (Lee, 2024; Vyas, 2022). Horizonte: corto-medio plazo.

Rec. O4. Monitorizar indicadores de WLB en los equipos con mayor uso de IA como parte del seguimiento de bienestar. Dado que los efectos negativos de la IA sobre la conciliación son detectables a escala poblacional con datos EWCS, también pueden medirse a escala de equipo con instrumentos más sencillos. Las organizaciones deberían incorporar preguntas sobre trabajo en tiempo libre, tensión fuera del horario y percepción global de la conciliación en sus encuestas periódicas de clima o pulso, desagregadas por nivel de uso de IA. Esto permite

detectar precozmente señales de deterioro y corregir antes de que se traduzcan en absentismo, rotación o baja productividad. La identificación de los equipos de alta intensidad + alta adopción de IA como subgrupo de especial seguimiento es prioritaria, dado el efecto amplificador documentado. Horizonte: continuo, desde el primer trimestre post-despliegue.

Rec. O5. Diseñar el teletrabajo como complemento activo de la gestión de límites, no como solución autónoma. Los resultados muestran que el teletrabajo mitiga parcialmente el desbordamiento temporal asociado a la IA, pero no protege frente a la tensión cognitiva: la interacción entre IA y teletrabajo reduce el trabajo en tiempo libre, pero no tiene efecto sobre la preocupación laboral fuera del horario. Esto significa que combinar teletrabajo con adopción de IA ayuda a reorganizar el tiempo, pero no resuelve el componente cognitivo y emocional del conflicto. Las organizaciones deben complementar las políticas de teletrabajo con intervenciones sobre el diseño de la tarea (reducir la ambigüedad de rol, limitar el número de proyectos simultáneos asistidos por IA) y programas de bienestar digital que aborden específicamente la desconexión cognitiva: técnicas de cierre de jornada, rutinas de recuperación y espacios de desfragmentación atencional. Horizonte: medio plazo, integrado en la política de trabajo híbrido.

Rec. O6. Priorizar la intervención en pymes, donde los marcos de conciliación son más débiles (Lamane-Harima et al., 2023). Los datos muestran que los trabajadores en pymes tienen menor predicibilidad horaria y peores resultados de WLB en varias dimensiones. En las pymes, la adopción de IA generativa suele producirse sin departamentos de RRHH formalizados, sin políticas de uso documentadas y con menor capacidad de seguimiento. Las asociaciones empresariales, cámaras de comercio y organismos de apoyo a pymes deberían desarrollar guías de adopción responsable de IA específicamente diseñadas para empresas sin estructura de RRHH dedicada, con herramientas sencillas de gestión de carga y plantillas de política de desconexión adaptadas a pequeños equipos. Horizonte: medio plazo, en coordinación con organismos de apoyo empresarial.

## **6.2. Recomendaciones para responsables de política pública**

Las siguientes recomendaciones se dirigen a responsables de política pública a nivel europeo y nacional: legisladores, agencias de inspección de trabajo, interlocutores sociales y

organismos de evaluación tecnológica. Se ordenan por palanca regulatoria, distinguiendo entre marcos ya existentes que requieren ampliación y marcos nuevos que deben desarrollarse.

Rec. P1. Ampliar el AI Act para incluir evaluaciones de impacto específicas sobre WLB en sistemas GPAI desplegados en el trabajo. El AI Act (Reglamento UE 2024/1689) exige evaluaciones de riesgo para sistemas de IA de alto riesgo en el lugar de trabajo, pero no aborda los sistemas de propósito general (GPAI), como los asistentes de IA generativa, que no toman decisiones sobre el empleo, pero sí reconfiguran la experiencia laboral. Los resultados de este trabajo documentan efectos significativos sobre la conciliación en una muestra de 25.138 trabajadores de la UE-27. En consecuencia, se recomienda que la Comisión Europea incorpore, en el desarrollo de los códigos de práctica GPAI previstos en el AI Act, requisitos de transparencia sobre el impacto en condiciones de trabajo: medidas de uso efectivo fuera del horario laboral, datos agrupados por sector y ocupación, y compromisos de divulgación a los representantes de los trabajadores. Horizonte: corto plazo; los códigos de práctica GPAI están entrando en aplicación tras agosto de 2025 y deben consolidarse en los próximos ciclos regulatorios.

Rec. P2. Adoptar una Directiva europea sobre derecho a la desconexión que contemple explícitamente el uso de IA generativa. Los datos muestran que los usuarios de IA generativa trabajan significativamente más en su tiempo libre tras controlar por horas semanales, sector, ocupación y país, lo que documenta empíricamente un riesgo que el Parlamento Europeo identificó en 2021 y la Comisión consultó en 2024. La futura Directiva, cuya negociación debe retomarse con urgencia, debería: (i) establecer el derecho a la desconexión como un derecho laboral fundamental, no como una recomendación; (ii) exigir a los empleadores planes de uso responsable de herramientas digitales e IA que incluyan protocolos de disponibilidad; y (iii) prever mecanismos de inspección y cumplimiento que den credibilidad práctica al derecho. La evidencia de este estudio puede emplearse directamente como justificación cuantitativa en el debate legislativo. Horizonte: corto-medio plazo (legislatura 2024–2029).

Rec. P3. Incorporar indicadores de IA generativa y WLB en el marco de seguimiento de la Estrategia Europea de Cuidados y el Pilar Europeo de Derechos Sociales. El Pilar Europeo de

Derechos Sociales incluye el principio 9 (equilibrio entre vida profesional y vida privada) como uno de sus ejes fundamentales, y la Estrategia Europea de Cuidados (2022–2030) reconoce la conciliación como condición estructural de la participación laboral. Sin embargo, ninguno de estos marcos recoge actualmente indicadores sobre el impacto de la IA generativa en la WLB. Se recomienda que Eurofound y la Comisión integren en el cuadro de indicadores del Pilar Social al menos dos medidas: (i) la tasa de trabajo en tiempo personal atribuible al uso de herramientas digitales e IA (adaptando los ítems pertinentes de la EWCS); y (ii) la brecha de conciliación entre usuarios y no usuarios de IA por género, cluster institucional y tamaño de empresa. Esto permitiría un seguimiento sistemático del impacto social de la transición a la IA laboral en toda la UE. Horizonte: medio plazo; puede incorporarse en la próxima revisión del cuadro de indicadores del Pilar Social (2026–2027).

Rec. P4. Reforzar los mecanismos de información y consulta de trabajadores sobre adopción de IA, con énfasis en sus impactos sobre condiciones de trabajo. El AI Act reconoce derechos de información para los trabajadores afectados por sistemas de IA de alto riesgo en el lugar de trabajo, pero estos derechos son de aplicación estrecha y no se extienden a los sistemas GPAI de uso genérico. Los resultados de este estudio sugieren que la implantación de IA generativa tiene consecuencias medibles sobre la conciliación que los trabajadores y sus representantes deberían poder anticipar y negociar. Se recomienda ampliar los derechos de información y consulta en la Directiva sobre Comités de Empresa Europeos y en las legislaciones nacionales de participación, de modo que cualquier decisión de adopción de herramientas de IA generativa a escala de empresa requiera consulta previa a los representantes de los trabajadores, con información sobre el impacto esperado en carga de trabajo y disponibilidad. Horizonte: medio plazo, en la revisión de la Directiva 2009/38/CE sobre comités de empresa europeos.

Rec. P5. Desarrollar políticas diferenciadas por cluster institucional que aceleren la convergencia en marcos de protección WLB. La heterogeneidad entre clusters documentada en el análisis descriptivo, con los países Nórdicos combinando alta adopción de IA y buena WLB, frente a los clusters Mediterráneo y de Europa del Este con menor adopción pero marcos de protección más débiles, sugiere que una política de talla única no será suficiente. Los fondos estructurales europeos, en particular el Fondo Social Europeo Plus (FSE+), deberían priorizar en los clusters con mayor vulnerabilidad: (i) programas de fortalecimiento de la capacidad

negociadora de los sindicatos en materia de IA laboral; (ii) apoyo técnico a las inspecciones de trabajo para incluir el uso de IA en sus protocolos de verificación de condiciones; y (iii) incentivos a la negociación colectiva sectorial sobre uso responsable de IA, tomando como modelo los acuerdos ya alcanzados en países Nórdicos en sectores como la banca y la Administración. Horizonte: medio-largo plazo, vinculado a los ciclos de programación del FSE+ 2021–2027 y 2028–2034.

Rec. P6. Invertir en datos longitudinales sobre IA y WLB para superar la limitación causal de los estudios transversales. La limitación metodológica más importante de este trabajo, compartida con toda la literatura empírica disponible sobre IA y WLB a escala europea, es la naturaleza transversal de los datos. Para fundamentar políticas basadas en evidencia sólida, se necesitan datos de panel que observen a los mismos trabajadores antes y después de la adopción de IA generativa. Se recomienda que Eurofound, en coordinación con los institutos nacionales de estadística, diseñe un módulo longitudinal sobre transformación digital del trabajo dentro de la infraestructura de la EWCS, con seguimiento bienal de una submuestra de trabajadores. Esto permitiría identificar relaciones causales, cuantificar efectos heterogéneos por tipo de herramienta y ocupación, y evaluar la efectividad de las intervenciones regulatorias a medida que se implementan. Horizonte: medio-largo plazo; puede incorporarse en la planificación de la próxima ola EWCS (2028–2030).

En conjunto, estas doce recomendaciones, seis para organizaciones y seis para responsables de política pública, configuran una agenda de acción coherente con los hallazgos del estudio. Su lógica común puede resumirse en tres principios: primero, la adopción de IA generativa debe ir acompañada siempre de una gestión activa de la carga de trabajo, pues la tecnología no reduce automáticamente las demandas; segundo, la autonomía y la flexibilidad requieren normas explícitas de desconexión para no convertirse en facilitadores del desbordamiento; y tercero, el contexto institucional importa: los marcos de negociación colectiva, los derechos de información y los mecanismos de inspección son los guardianes que determinan si la transición a la IA laboral se traduce en ganancias de bienestar o en una nueva vuelta de tuerca a la intensificación del trabajo.

## 7. Referencias

- Azpíroz-Dorronsoro, M., Erro-Garcés, A., & Etayo-Pérez, M. (2024). Technostress and Work-Family Conflict in ICT-User Employees during the COVID-19 Pandemic. *Behaviour & Information Technology*, 43(8), 1531–1553. <https://doi.org/10.1080/0144929X.2023.2220051>
- Bakker, A. B., & Demerouti, E. (2007). The Job Demands-Resources model: State of the art. *Journal of Managerial Psychology*, 22(3), 309–328. <https://doi.org/10.1108/02683940710733115>
- Bakker, A. B., & Demerouti, E. (2017). Job Demands–Resources Theory: Taking Stock and Looking Forward. *Journal of Occupational Health Psychology*, 22(3), 273–285. <https://doi.org/10.1037/ocp0000056>
- Baumeister, V. M., Kuen, L. P., Bruckes, M., & Schewe, G. (2021). The Relationship of Work-Related ICT Use With Well-being, Incorporating the Role of Resources and Demands: A Meta-Analysis. *Sage Open*. <https://doi.org/10.1177/21582440211061560>
- Chen, F., & Li, R. (2024). Improvement and Replacement: The Dual Impact of Automation on Employees' Job Satisfaction. *Systems*, 12(2), 46. <https://doi.org/10.3390/systems12020046>
- Chesley, N. (2014). Information and Communication Technology Use, Work Intensification and Employee Strain and Distress. *Work, Employment and Society*, 28(4), 589–610. <https://doi.org/10.1177/0950017013500112>
- Derks, D., van Duin, D., Tims, M., & Bakker, A. B. (2016). Work-Related Smartphone Use, Work–Family Conflict and Family Role Performance. *Human Relations*, 69(5), 1045–1068. <https://doi.org/10.1177/0018726715601890>
- Esping-Andersen, G. (1990). *The Three Worlds of Welfare Capitalism*. Princeton University Press.
- Eurofound. (2025). *European Working Conditions Survey 2024/2025: Technical report and user guide*. Publications Office of the European Union. <https://www.eurofound.europa.eu/en/surveys/ewcs>
- European Commission. (2024). *Consultation of the social partners under Article 154 TFEU on a possible revision of the Council Directive on certain aspects of the organisation of working time*. Publications Office of the European Union. <https://ec.europa.eu/social/main.jsp?catId=521&langId=en>
- European Parliament. (2021). *Resolution of 21 January 2021 with recommendations to the Commission on the right to disconnect (2019/2181(INI))*. Official Journal of the European Union. [https://www.europarl.europa.eu/doceo/document/TA-9-2021-0021\\_EN.html](https://www.europarl.europa.eu/doceo/document/TA-9-2021-0021_EN.html)

- Fan, Y., Potočnik, K., & Chaudhry, S. (2021). A process-oriented, multilevel, multidimensional conceptual framework of work–life balance support: A multidisciplinary systematic literature review and future research agenda. *International Journal of Management Reviews*, 23, 486–515. <https://doi.org/10.1111/ijmr.12254>
- Ferraro, T., Pais, L., dos Santos, N. R., & Moreira, J. M. (2016). The Decent Work Agenda: A Systematic Review. *Career Development International*, 21(4), 390–412. <https://doi.org/10.1108/CDI-12-2015-0187>
- Green, F., & Mostafa, T. (2012). *Trends in Job Quality in Europe*. Eurofound, Publications Office of the European Union. <https://www.eurofound.europa.eu/en/publications/2012/trends-job-quality-europe>
- Haar, J. M. (2013). Testing a new measure of work-life balance: A study of parent and non-parent employees from New Zealand. *The International Journal of Human Resource Management*, 24(17), 3305–3324. <https://doi.org/10.1080/09585192.2013.775175>
- Haar, J., & Brougham, D. (2022). Work antecedents and consequences of work-life balance: A two sample study within New Zealand. *The International Journal of Human Resource Management*, 33(4), 784–807. <https://doi.org/10.1080/09585192.2020.1751238>
- Haar, J., & Harris, C. (2025). Does organizational support for work-life balance enhance worker work-life balance? Testing effects beyond supporting the family. *The International Journal of Human Resource Management*, 36(17), 3026–3051. <https://doi.org/10.1080/09585192.2025.2582614>
- Hall, P. A., & Soskice, D. (2001). *Varieties of Capitalism: The Institutional Foundations of Comparative Advantage*. Oxford University Press. <https://doi.org/10.1093/0199247757.001.0001>
- Hildenbrand, K., Daher, P., Topakas, A., & Gan, X. (2024). Multidimensional work-nonwork balance: Are balanced employees productive at work and satisfied with life? *The International Journal of Human Resource Management*, 35(6), 1048–1087. <https://doi.org/10.1080/09585192.2023.2258335>
- Hobfoll, S. E. (1989). Conservation of resources: A new attempt at conceptualizing stress. *American Psychologist*, 44(3), 513–524. <https://doi.org/10.1037/0003-066X.44.3.513>
- Kelliher, C., & Anderson, D. (2010). Doing More with Less? Flexible Working Practices and the Intensification of Work. *Human Relations*, 63(1), 83–106. <https://doi.org/10.1177/0018726709349199>
- Lamane-Harima, J., Cegarra-Leiva, D., & Sánchez-Vidal, M. E. (2023). Work–life balance supportive culture: A way to retain employees in Spanish SMEs. *The International Journal of Human Resource Management*, 34(10), 2074–2106. <https://doi.org/10.1080/09585192.2021.1878255>

- Lee, J. (2024). Working in the Era of AI: Balancing AI Integration and Employee Well-Being Across Contexts and Cultures. In *Proceedings of SOCIOINT 2024 – 11th International Conference on Education & Social Sciences*.  
<https://doi.org/10.5281/zenodo.11181970>
- Parent-Rochelleau, X., & Parker, S. K. (2022). Algorithms as Work Designers: How Algorithmic Management Influences the Design of Jobs. *Human Resource Management Review*, 32(2), 100795. <https://doi.org/10.1016/j.hrmr.2021.100795>
- Saunders, M., Lewis, P., & Thornhill, A. (2023). *Research methods for business students* (9th ed.). Pearson Education.
- Vyas, L. (2022). "New normal" at work in a post-COVID world: Work–life balance and labor markets. *Policy and Society*, 41(1), 155–167. <https://doi.org/10.1093/polsoc/puab011>
- Zhang, X., Liu, S., Chen, X., & Gong, Y. (2025). The Rise of Algorithmic Management and Implications for Work and Organisations. *New Technology, Work and Employment*.  
<https://doi.org/10.1111/ntwe.12343>

## 8. Declaration of the use of AI

### Declaration of Use of Generative Artificial Intelligence Tools in Final Degree Projects

I, Luis Málaga, student of E2 + Analytics at Universidad Pontificia Comillas, upon submitting my Final Degree Project titled “Evaluación de la conciliación vida-trabajo con la introducción de IA generativa en el espacio laboral de la UE”, declare that I have used the Generative Artificial Intelligence tool ChatGPT or similar code-based GAI tools **only** in the context of the activities described below:

1. **Critical perspective:** Used to find counterarguments to a specific thesis I intended to defend.
2. **References:** Used alongside other tools, such as Science, to identify preliminary references that I later cross-checked and validated.
3. **Code interpreter:** Used to perform preliminary data analysis.
4. **Multidisciplinary studies:** Used to understand perspectives from other communities on topics of a multidisciplinary nature.
5. **Literary and language style editor:** Used to improve the linguistic and stylistic quality of the text.
6. **Summarizer and explainer of complex books:** Used to summarize and understand complex literature.
7. **Reviewer:** Used to receive suggestions on how to improve and refine the work with different levels of rigor.
8. **Translator:** Used to translate texts from one language to another.

I affirm that all information and content presented in this work are the result of my individual research and effort, except where otherwise indicated and proper credit has been given (I have included appropriate references in the Final Degree Project and explicitly stated how ChatGPT or similar tools were used). I am aware of the academic and ethical implications of submitting non-original work and accept the consequences of any violation of this declaration.

**Date:** 20/04/2026

**Signature:** Luis Málaga Santaella



## 9. Apéndice A. Código de análisis en Python

El siguiente código Python implementa íntegramente el análisis estadístico descrito en la Sección 3. Incluye la construcción de variables, el análisis descriptivo, las correlaciones de Spearman, el test VIF, los modelos OLS stepwise con errores estándar robustos HC3 y las pruebas de robustez. Para ejecutarlo es necesario las librerías pandas, numpy, matplotlib, seaborn, statsmodels y scipy, y disponer del fichero de datos ewcs24\_dataset\_ukds.csv del UK Data Service (Eurofound, 2025).

```
#!/usr/bin/env python3
# -*- coding: utf-8 -*-
"""
=====
TFG: Evaluación de la conciliación vida-trabajo con la introducción de
IA generativa en el espacio laboral de la UE
Autor: Luis Málaga Santaella
Datos: European Working Conditions Survey (EWCS) 2024/25
Fuente: UK Data Service / Eurofound
Fecha: 2026
=====

ESTRUCTURA DEL SCRIPT
-----
0. Importaciones y configuración
1. Carga y selección de muestra UE-27
2. Construcción de variables
3. Análisis descriptivo - genera imágenes PNG
  3.1 Tabla 3.1 - Clasificación por cluster institucional
  3.2 Tabla 3.2 - Estadísticos descriptivos
  3.3 Figura 3.1 - Adopción IA por país, sector y ocupación
  3.4 Figura 3.2 - Comparación WLB usuarios vs. no usuarios
  3.5 Figura 3.3 - WLB, IA y pymes por cluster
  3.6 Figura 3.4 - Distribución de DVs por grupo
4. Correlaciones de Spearman - Figura 3.5
5. Test VIF - Tabla 3.3
6. Modelos OLS stepwise - Tablas 4.1-4.8 y Figura 4.1
7. Pruebas de robustez

NOTAS DE REPRODUCIBILIDAD
-----
- Ajustar DATA_PATH antes de ejecutar.
- En Google Colab: DATA_PATH = '/content/ewcs24_dataset_ukds.csv'
- Todas las figuras y tablas se guardan como PNG en OUTPUT_DIR.
- N muestra modelo: 25.138 observaciones con datos completos.
- Estimador: OLS con errores estándar robustos HC3.
- DVs invertidas: dirección depende de la dimensión
  · D1, D5: coeficiente positivo = mejor WLB
  · D2, D3, D4: coeficiente positivo = peor WLB (más interferencia/desbordamiento)
  La interpretación de cada  $\beta$  se reporta explícitamente en §4.2-§4.6.
=====
"""

# =====
# 0. IMPORTACIONES Y CONFIGURACIÓN
# =====

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.patches as mpatches
import matplotlib.gridspec as gridspec
import seaborn as sns
import statsmodels.api as sm
from statsmodels.stats.outliers_influence import variance_inflation_factor
from scipy import stats
import warnings
import os
import sys
```

```

warnings.filterwarnings('ignore')

# --- Rutas -----
DATA_PATH = "ewcs24_dataset_ukds.csv" # Ajustar si necesario
OUTPUT_DIR = "outputs/"
os.makedirs(OUTPUT_DIR, exist_ok=True)

# --- Paleta de colores del TFG -----
C_DARK = '#1F3864'
C_MID = '#2E75B6'
C_LIGHT = '#9DC3E6'
C_WHITE = '#FFFFFF'
C_GREY = '#595959'
C_RED = '#C00000'
C_AMBER = '#FFC000'
C_GREEN = '#70AD47'

CLUSTER_COLORS = {
    'Nórdico': '#1F3864',
    'Continental': '#2E75B6',
    'Liberal': '#70AD47',
    'Mediterráneo': '#FFC000',
    'Europa del Este': '#C00000',
}

print("=" * 70)
print(" TFG - IA Generativa y WLB en la UE (EWCS 2024/25) [v9]")
print("=" * 70)
print(f" Python {sys.version.split()[0]} | pandas {pd.__version__} | "
      f"statsmodels {sm.__version__}")
print()

# --- Función auxiliar para guardar tablas como PNG -----
def table_to_png(df_table, filename, title, col_widths=None,
                figsize=None, fontsize=9):
    """
    Guarda un DataFrame como tabla PNG con formato limpio.
    Útil para Tabla 3.1, 3.2, 3.3 y tablas de resultados.
    """
    n_rows, n_cols = df_table.shape
    if figsize is None:
        figsize = (max(10, n_cols * 1.8), max(2, n_rows * 0.38 + 1.2))

    fig, ax = plt.subplots(figsize=figsize, facecolor=C_WHITE)
    ax.axis('off')

    tbl = ax.table(
        cellText=df_table.values,
        colLabels=df_table.columns,
        cellLoc='center',
        loc='center',
    )

    tbl.auto_set_font_size(False)
    tbl.set_fontsize(fontsize)
    tbl.scale(1, 1.6)

    # Header style
    for j in range(n_cols):
        cell = tbl[0, j]
        cell.set_facecolor(C_DARK)
        cell.set_text_props(color='white', fontweight='bold')

    # Alternating row colors
    for i in range(1, n_rows + 1):
        bg = '#F2F7FC' if i % 2 == 0 else C_WHITE
        for j in range(n_cols):
            tbl[i, j].set_facecolor(bg)
            tbl[i, j].set_edgecolor('#DDDDDD')

    # Column widths
    if col_widths:
        for j, w in enumerate(col_widths):
            for i in range(n_rows + 1):
                tbl[i, j].set_width(w)

    ax.set_title(title, fontsize=fontsize + 1, fontweight='bold',
                color=C_DARK, pad=10, loc='left')

```

```

plt.tight_layout()
out = os.path.join(OUTPUT_DIR, filename)
plt.savefig(out, dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(f"    {filename} guardada")

# =====
# 1. CARGA Y SELECCIÓN UE-27
# =====

print("1. Cargando dataset EWCS 2024/25...")

df_raw = pd.read_csv(DATA_PATH, encoding='latin-1', sep=';', low_memory=False)
print(f"    Dataset completo: {len(df_raw):,} obs × {df_raw.shape[1]} variables")

EU27 = {'AT','BE','BG','CY','CZ','DE','DK','EE','ES','FI','FR',
        'GR','HR','HU','IE','IT','LT','LU','LV','MT','NL','PL',
        'PT','RO','SE','SI','SK'}

df_raw['country_code'] = df_raw['country_code'].astype(str).str.strip().str.upper()
df = df_raw[df_raw['country_code'].isin(EU27)].copy()
print(f"    Muestra UE-27: {len(df):,} observaciones")

# =====
# 2. CONSTRUCCIÓN DE VARIABLES
# =====

print("\n2. Construyendo variables...")

def clean_invert(series, max_val):
    """
    Filtra valores fuera del rango [1, max_val] (incluye -991, -998, -999)
    e invierte la escala: nuevo = (max_val + 1) - original.
    Dirección resultante por dimensión:
    - D1 (work_life_balance): valor mayor = mejor WLB (mejor encaje global)
    - D2 (wlb_timefamily):    valor mayor = peor WLB (más interferencia temporal)
    - D3 (freetime_work):     valor mayor = peor WLB (más trabajo en tiempo libre)
    - D4 (wlb_worry):         valor mayor = peor WLB (más tensión cognitiva)
    - D5 (emp_wt_predict):    valor mayor = mejor WLB (mayor predicibilidad)
    La interpretación del coeficiente  $\beta$  en los modelos OLS depende por tanto de
    la dimensión analizada y se reporta explícitamente en cada sub-sección $4.2-$4.6.
    """
    s = pd.to_numeric(series, errors='coerce')
    s = s.where(s >= 1, np.nan).where(s <= max_val, np.nan)
    return (max_val + 1) - s

# DVs (dirección tras inversión: D1,D5 ↑=mejor WLB; D2,D3,D4 ↑=peor WLB)
df['D1'] = clean_invert(df['work_life_balance'], 4)    # 1=Nada bien → 4=Muy bien
df['D2'] = clean_invert(df['wlb_timefamily'], 5)      # -991 filtrado → NaN [H2:
interferencia temporal]
df['D3'] = clean_invert(df['freetime_work'], 5)      # 1=Cada día → 5=Nunca [H3: trabajo
fuera de horario]
df['D4'] = clean_invert(df['wlb_worry'], 5)          # -991 filtrado → NaN
df['D5'] = clean_invert(df['emp_wt_predict'], 3)      # 1=Nunca predic → 3=Siempre

DVs = {'D1':'Encaje global WLB','D2':'Interferencia tiempo-familia',
        'D3':'Trabajo fuera de horario','D4':'Interferencia por tensión',
        'D5':'Predicibilidad del horario'}

# Variable explicativa: IA generativa (1=usa, 0=no usa)
df['genai_dummy'] = pd.to_numeric(df['tech_genAI'], errors='coerce')
df['genai_dummy'] = np.where(df['genai_dummy']==1, 1,
                             np.where(df['genai_dummy']==2, 0, np.nan))

# Género (sex2: 1=Hombre, 2=Mujer → female=1)
df['female'] = np.where(pd.to_numeric(df['sex2'],errors='coerce')==2, 1,
                        np.where(pd.to_numeric(df['sex2'],errors='coerce')==1, 0, np.nan))

# Edad
df['age'] = pd.to_numeric(df['age_discrete'],errors='coerce').where(
    lambda x: x.between(15,80), np.nan)
df['age2'] = df['age']**2

# Educación ISCED (variable correcta: nivel personal, no del hogar)

```

```

iscd = pd.to_numeric(df['iscd'],errors='coerce').where(lambda x: x>=0, np.nan)
df['edu_low'] = np.where(iscd.isin([0,1,2]),1,np.where(iscd.notna(),0,np.nan))
df['edu_med'] = np.where(iscd.isin([3,4]), 1,np.where(iscd.notna(),0,np.nan))
df['edu_high'] = np.where(iscd>=5, 1,np.where(iscd.notna(),0,np.nan))

# Contrato (solo para sensitivity check)
ec = pd.to_numeric(df['empl_contract'],errors='coerce')
df['permanent'] = np.where(ec==1, 1, np.where(ec.isin([2,3,4,5]),0,np.nan))

# Condición laboral (1=asalariado, 0=autónomo)
emp = pd.to_numeric(df['employee_selfdeclared'],errors='coerce')
df['employee_selfdeclared_bin'] = np.where(emp==1,1,np.where(emp==2,0,np.nan))

# Horas semanales (filtro: 1-80)
h = pd.to_numeric(df['usual_hours_week'],errors='coerce')
df['hours_week'] = h.where(h.between(1,80), np.nan)

# Pyme (wp_size 1-4 = ≤249 empleados)
ws = pd.to_numeric(df['wp_size'],errors='coerce')
df['sme'] = np.where(ws.isin([1,2,3,4]),1,np.where(ws.isin([5,6,7,8]),0,np.nan))

# Autonomía (media de 3 items, escala 1-5, ↑=más autonomía)
for v in ['autonomy_order','autonomy_methods','autonomy_speed']:
    df[v] = pd.to_numeric(df[v],errors='coerce').where(lambda x: x.between(1,5),np.nan)
df['autonomy_idx'] = df[['autonomy_order','autonomy_methods','autonomy_speed']].mean(axis=1)

# Intensidad laboral (highspeed + tightdead, escala 1-7, invertida: ↑=más intensidad)
# IMPORTANTE: EWCS 2024/25 usa escala 1-7 (no 1-5 como ediciones anteriores)
# Inversión: 8 - valor → 7=Siempre (alta), 1=Nunca (baja)
for v in ['highspeed','tightdead']:
    raw = pd.to_numeric(df[v],errors='coerce').where(lambda x: x.between(1,7),np.nan)
    df[v+'_inv'] = 8 - raw
df['intensity_idx'] = df[['highspeed_inv','tightdead_inv']].mean(axis=1)

# Teletrabajo (loc_home 1=Siempre casa → 5=Nunca, invertida: ↑=más teletrabajo)
lh = pd.to_numeric(df['loc_home'],errors='coerce').where(lambda x: x.between(1,5),np.nan)
df['telework_inv'] = 6 - lh

# Estandarización de moderadores (z-scores para comparabilidad)
for var, col in [('telework','telework_inv'),('autonomy','autonomy_idx'),
                ('intensity','intensity_idx')]:
    df[f'{var}_z'] = (df[col] - df[col].mean()) / df[col].std()

# Interacciones GenAI × moderadores
df['genai_dummy'] = df['genai_dummy'] # ya definido
df['genai_x_telework'] = df['genai_dummy'] * df['telework_z']
df['genai_x_autonomy'] = df['genai_dummy'] * df['autonomy_z']
df['genai_x_intensity'] = df['genai_dummy'] * df['intensity_z']

# Clusters institucionales
CLUSTERS = {
    'Nórdico': ['DK','FI','SE'],
    'Continental': ['AT','BE','DE','LU','NL'],
    'Liberal': ['IE'],
    'Mediterráneo': ['CY','ES','FR','GR','IT','MT','PT'],
    'Europa del Este': ['BG','CZ','EE','HR','HU','LT','LV','PL','RO','SI','SK'],
}
country_to_cluster = {c:k for k,v in CLUSTERS.items() for c in v}
df['cluster'] = df['country_code'].map(country_to_cluster)

# Sector NACE agrupado
NACE_MAP = {
    'A':'Industria/Agric.','B':'Industria/Agric.','C':'Industria/Agric.',
    'D':'Industria/Agric.','E':'Industria/Agric.','F':'Construcción',
    'G':'Comercio/Transport./Hostelería','H':'Comercio/Transport./Hostelería',
    'I':'Comercio/Transport./Hostelería','J':'Finanzas/TIC','K':'Finanzas/TIC',
    'L':'Servicios profesionales/Admin.','M':'Servicios profesionales/Admin.',
    'N':'Servicios profesionales/Admin.','O':'Administración pública',
    'P':'Educación','Q':'Sanidad/Servicios sociales',
    'R':'Otros servicios','S':'Otros servicios','T':'Otros servicios','U':'Otros servicios',
}
df["sector"] = df["NACE1"].astype(str).str.strip().str.upper().map(NACE_MAP) # NACE1 = letter
codes (A,B,...); NACE_2 = numeric codes (wrong)

# Dummies ISCO (ref=2=Profesionales), NACE (ref=Adm.pública), país (ref=ES)
df['ISCO_cat'] = df['ISCO_1'].astype('Int64').astype(str)
isco_dummies = pd.get_dummies(df['ISCO_cat'],prefix='isco').astype(float)

```

```

df = pd.concat([df, isco_dummies], axis=1)
isco_cols = sorted([c for c in isco_dummies.columns if c != 'isco_2'])

nace_dummies = pd.get_dummies(df['sector'], prefix='nace').astype(float)
df = pd.concat([df, nace_dummies], axis=1)
nace_cols = sorted([c for c in nace_dummies.columns
                    if c != 'nace_Administración pública' and c in df.columns])

ctry_dummies = pd.get_dummies(df['country_code'], prefix='ctry').astype(float)
df = pd.concat([df, ctry_dummies], axis=1)
ctry_cols = sorted([c for c in ctry_dummies.columns if c != 'ctry_ES'])

print(" Variables construidas correctamente.")

# =====
# 3. ANÁLISIS DESCRIPTIVO – TABLAS Y FIGURAS
# =====

print("\n3. Generando tablas y figuras descriptivas...")

mean_eu27 = df['genai_dummy'].mean() * 100

# — 3.1 TABLA 3.1 – Clasificación por cluster institucional —————
# Muestra: N, países, adopción IA y % pymes por cluster.
# Base teórica: Hall & Soskice (2001), Esping-Andersen (1990).
# N CORRECTOS verificados con el dataset real.

CLUSTER_INFO = {
    'Nórdico': ('DK, FI, SE', 3),
    'Continental': ('AT, BE, DE, LU, NL', 5),
    'Liberal': ('IE', 1),
    'Mediterráneo': ('CY, ES, FR, GR, IT, MT, PT', 7),
    'Europa del Este': ('BG, CZ, EE, HR, HU, LT, LV, PL, RO, SI, SK', 11),
}

rows_31 = []
for cl in ['Nórdico', 'Continental', 'Liberal', 'Mediterráneo', 'Europa del Este']:
    sub = df[df['cluster']==cl]
    n = len(sub)
    ia = sub['genai_dummy'].mean() * 100
    sme = sub['sme'].mean() * 100
    paises, n_paises = CLUSTER_INFO[cl]
    rows_31.append({
        'Cluster': cl,
        'Países (N)': f"{paises} ({n_paises})",
        'N muestra': f"{n:,}",
        'Adopción IA (%)': f"{ia:.1f}%",
        'Peso pymes (%)': f"{sme:.1f}%",
    })

# Total row
rows_31.append({
    'Cluster': 'TOTAL UE-27',
    'Países (N)': '27 paises',
    'N muestra': f"{len(df):,}",
    'Adopción IA (%)': f"{mean_eu27:.1f}%",
    'Peso pymes (%)': f"{df['sme'].mean()*100:.1f}%",
})

df_31 = pd.DataFrame(rows_31)
table_to_png(
    df_31,
    'Tabla3_1_Clusters.png',
    'Tabla 3.1. Clasificación de países UE-27 por clúster institucional. '
    'Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.',
    figsize=(13, 4),
    fontsize=9,
)

# — 3.2 TABLA 3.2 – Estadísticos descriptivos —————
# Variables del modelo: DVs, IV, moderadores y controles principales.
# N base: 28.621 (muestra UE-27 completa, no la muestra de modelo).
# Los missing% documentan las decisiones de diseño (permanent, contact_out_wh).

desc_vars = [
    ('D1', 'D1: Encaje global WLB', '1-4 (inv)'),

```

```

('D2', 'D2: Interf. tiempo-familia', '1-5 (inv.)'),
('D3', 'D3: Trabajo fuera de horario', '1-5 (inv.)'),
('D4', 'D4: Interf. por tensión', '1-5 (inv.)'),
('D5', 'D5: Predicibilidad horario', '1-3 (inv.)'),
('genai_dummy', 'IA generativa', '0/1'),
('telework_inv', 'Teletrabajo', '1-5 (inv.)'),
('autonomy_idx', 'Autonomía laboral', '1-5'),
('intensity_idx', 'Intensidad laboral', '1-7 (inv.)'),
('female', 'Mujer', '0/1'),
('age', 'Edad', 'años'),
('edu_low', 'Educación baja', '0/1'),
('edu_med', 'Educación media', '0/1'),
('edu_high', 'Educación alta', '0/1'),
('hours_week', 'Horas semanales', '1-80'),
('sme', 'Pyme (≤249 emp.)', '0/1'),
('employee_selfdeclared_bin', 'Asalariado', '0/1'),
]

rows_32 = []
for v, label, escala in desc_vars:
    if v in df.columns and df[v].notna().sum() > 0:
        s = df[v].dropna()
        rows_32.append({
            'Variable': label,
            'Escala': escala,
            'N': f"{len(s):,}",
            'Media': f"{s.mean():.3f}",
            'DE': f"{s.std():.3f}",
            'Mín.': f"{s.min():.1f}",
            'Máx.': f"{s.max():.1f}",
            'Missing %': f"{df[v].isna().mean()*100:.1f}%",
        })

df_32 = pd.DataFrame(rows_32)
table_to_png(
    df_32,
    'Tabla3_2_Descriptivos.png',
    f'Tabla 3.2. Estadísticos descriptivos (UE-27, N=28.621). ',
    f'Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.',
    figsize=(14, 7.5),
    fontsize=8.5,
)

# — 3.3 FIGURA 3.1 – Adopción IA por país, sector y ocupación —————
# Tres paneles horizontales. Línea discontinua roja = media UE-27 (11,2%).
# Justifica variabilidad cross-country → necesidad de efectos fijos de país.

genai_country = (df.groupby('country_code')['genai_dummy']
                 .agg(['mean', 'count']).reset_index())
genai_country.columns = ['country', 'adoption_rate', 'n']
genai_country['adoption_pct'] = genai_country['adoption_rate'] * 100
genai_country['cluster'] = genai_country['country'].map(country_to_cluster)
genai_country = genai_country.sort_values('adoption_pct')

fig, axes = plt.subplots(1, 3, figsize=(18, 7), facecolor=C_WHITE)

# Panel A – por país
ax = axes[0]
colors = [CLUSTER_COLORS.get(r['cluster'], '#999') for _, r in genai_country.iterrows()]
ax.barh(genai_country['country'], genai_country['adoption_pct'],
        color=colors, alpha=0.85)
ax.axvline(mean_eu27, color=C_RED, lw=1.5, ls='--',
           label=f'Media UE-27 ({mean_eu27:.1f}%)')
ax.set_xlabel('Adopción IA generativa (%)', fontsize=9)
ax.set_title('A) Por país (coloreado por clúster)', fontsize=10, fontweight='bold')
ax.legend(fontsize=8)
ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)

# Panel B – por sector NACE
ax = axes[1]
genai_sector = (df.groupby('sector')['genai_dummy'].mean()
                .dropna().sort_values() * 100)
ax.barh(genai_sector.index, genai_sector.values, color=C_MID, alpha=0.85)
ax.axvline(mean_eu27, color=C_RED, lw=1.5, ls='--')
ax.set_xlabel('Adopción IA generativa (%)', fontsize=9)
ax.set_title('B) Por sector (NACE)', fontsize=10, fontweight='bold')
ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)

```

```

# Panel C – por ocupación ISCO-1
ax = axes[2]
ISCO_LABELS = {1:'Directivos',2:'Profesionales',3:'Técnicos',
               4:'Administrativos',5:'Servicios/Ventas',6:'Agric./Pesca',
               7:'Artesanos',8:'Operadores',9:'Elem. básicas'}
df['isco_label'] = df['ISCO_1'].map(ISCO_LABELS)
genai_isco = (df.groupby('isco_label')['genai_dummy'].mean()
              .dropna().sort_values() * 100)
ax.barh(genai_isco.index, genai_isco.values, color=C_DARK, alpha=0.85)
ax.axvline(mean_eu27, color=C_RED, lw=1.5, ls='--')
ax.set_xlabel('Adopción IA generativa (%)', fontsize=9)
ax.set_title('C) Por ocupación (ISCO-1)', fontsize=10, fontweight='bold')
ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)

handles = [mpatches.Patch(color=c,label=k) for k,c in CLUSTER_COLORS.items()]
fig.legend(handles=handles, loc='lower center', ncol=5, fontsize=8,
           bbox_to_anchor=(0.5,-0.03), framealpha=0.9)
fig.text(0.5,-0.01,
        'Línea discontinua = media UE-27. Fuente: EWCS 2024/25 (Eurofound).',
        ha='center', fontsize=8, color=C_GREY)
plt.tight_layout(rect=[0,0.04,1,0.95])
plt.savefig(os.path.join(OUTPUT_DIR,'Fig3_1_Adopcion_IA.png'),
           dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(" Fig3_1_Adopcion_IA.png guardada")

# — 3.4 FIGURA 3.2 – Comparación WLB: usuarios vs. no usuarios de IA —————
# Barras de medias con IC 95% y test Mann-Whitney.
# Muestra diferencias brutas (sin controlar covariables) – anticipa resultados.

dv_labels_short = {
    'D1':'Encaje WLB','D2':'Interf. tiempo',
    'D3':'Fuera horario','D4':'Interf. tensión','D5':'Predic. horario',
}

fig, axes = plt.subplots(1, 5, figsize=(16,5), facecolor=C_WHITE)
fig.patch.set_facecolor(C_WHITE)

for i, (dv, label) in enumerate(DVs.items()):
    ax = axes[i]
    g0 = df.loc[df['genai_dummy']==0, dv].dropna()
    g1 = df.loc[df['genai_dummy']==1, dv].dropna()
    m0, m1 = g0.mean(), g1.mean()
    se0 = g0.std()/np.sqrt(len(g0))
    se1 = g1.std()/np.sqrt(len(g1))
    ax.bar([0,1],[m0,m1], color=[C_LIGHT,C_DARK], alpha=0.85, width=0.5)
    ax.errorbar([0,1],[m0,m1], yerr=[1.96*se0,1.96*se1],
               fmt='none', color='black', capsize=5, lw=1.5)
    _, p = stats.mannwhitneyu(g0, g1, alternative='two-sided')
    sig = '***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else 'n.s.'))
    ax.set_title(f'{dv}\n{dv_labels_short[dv]}\n{sig}', fontsize=9)
    ax.set_xticks([0,1])
    ax.set_xticklabels(['No IA','IA gen.'], fontsize=8)
    ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)
    ax.set_ylabel('Media (invertida)' if i==0 else '', fontsize=8)

fig.suptitle('Figura 3.2. Medias de las dimensiones WLB por grupo de uso de IA generativa '
            '(IC 95%, test Mann-Whitney)',
            fontsize=10, fontweight='bold', color=C_DARK)
handles_f32 = [mpatches.Patch(color=C_LIGHT,label='No usa IA (N≈25.231)'),
               mpatches.Patch(color=C_DARK,label='Usa IA (N≈3.181)')]
fig.legend(handles=handles_f32, loc='lower center', ncol=2, fontsize=8,
           bbox_to_anchor=(0.5,-0.04), framealpha=0.9)
fig.text(0.5,-0.02,'DVs invertidas: D1/D5 ↑ = mejor WLB; D2/D3/D4 ↑ = peor WLB. Fuente: EWCS
2024/25 (Eurofound).',
        ha='center', fontsize=8, color=C_GREY)
plt.tight_layout(rect=[0,0.06,1,0.94])
plt.savefig(os.path.join(OUTPUT_DIR,'Fig3_2_WLB_Comparativo.png'),
           dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(" Fig3_2_WLB_Comparativo.png guardada")

# — 3.5 FIGURA 3.3 – WLB, IA y pymes por cluster —————
# Tres paneles por cluster. Ilustra heterogeneidad institucional.
# Justifica efectos hijos de país: los países difieren sistemáticamente.

```

```

cluster_order = ['Nórdico','Continental','Liberal','Mediterráneo','Europa del Este']
cluster_stats = df.groupby('cluster').agg(
    wlb_mean=('D1','mean'),
    ia_pct=('genai_dummy', lambda x: x.mean()*100),
    pyme_pct=('sme', lambda x: x.mean()*100),
).reindex(cluster_order).reset_index()

fig, axes = plt.subplots(1, 3, figsize=(15,5), facecolor=C_WHITE)
fig.suptitle('Figura 3.3. WLB global, adopción de IA generativa y peso de pymes '
            'por clúster institucional (UE-27)',
            fontsize=10, fontweight='bold', color=C_DARK)

clust_colors = [CLUSTER_COLORS[c] for c in cluster_order]

for ax, col, title, ylabel, fmt in [
    (axes[0], 'wlb_mean', 'A) Encaje WLB global (D1)', 'Media D1 (↑=mejor)', '%.2f'),
    (axes[1], 'ia_pct', 'B) Adopción IA generativa', 'Adopción (%)', '%.1f%%'),
    (axes[2], 'pyme_pct', 'C) Peso de pymes (≤249 emp.)', 'Porcentaje (%)', '%.1f%%'),
]:
    bars = ax.bar(cluster_stats['cluster'], cluster_stats[col],
                  color=clust_colors, alpha=0.85)
    ax.set_title(title, fontsize=10)
    ax.set_ylabel(ylabel, fontsize=9)
    ax.tick_params(axis='x', rotation=20, labelsiz=8)
    ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)
    for bar, val in zip(bars, cluster_stats[col]):
        ax.text(bar.get_x()+bar.get_width()/2, bar.get_height()+0.3,
                fmt % val, ha='center', va='bottom', fontsize=8, color=C_GREY)

fig.text(0.5,-0.01,'Fuente: EWCS 2024/25 (Eurofound). Elaboración propia.',
        ha='center', fontsize=8, color=C_GREY)
plt.tight_layout()
plt.savefig(os.path.join(OUTPUT_DIR,'Fig3_3_Clusters.png'),
            dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(" Fig3_3_Clusters.png guardada")

# — 3.6 FIGURA 3.4 – Distribución de DVs por grupo —————
# Histogramas de cada DV separados por usuarios y no usuarios de IA.
# Muestra que las distribuciones son razonablemente simétricas → válida OLS.
# Permite ver si las diferencias están en la cola o distribuidas uniformemente.

fig, axes = plt.subplots(2, 5, figsize=(18, 8), facecolor=C_WHITE)
fig.suptitle('Figura 3.4. Distribución de las dimensiones WLB (D1-D5) '
            'por grupo de uso de IA generativa',
            fontsize=11, fontweight='bold', color=C_DARK)

dv_ranges = {'D1':(1,4),'D2':(1,5),'D3':(1,5),'D4':(1,5),'D5':(1,3)}

for j, (dv, label) in enumerate(DVs.items()):
    g0 = df.loc[df['genai_dummy']==0, dv].dropna()
    g1 = df.loc[df['genai_dummy']==1, dv].dropna()
    mn, mx = dv_ranges[dv]
    bins = np.arange(mn-0.5, mx+1.5, 1)

    # Top row: No IA
    ax0 = axes[0, j]
    ax0.hist(g0, bins=bins, color=C_LIGHT, alpha=0.85, edgecolor='white', density=True)
    ax0.axvline(g0.mean(), color=C_DARK, lw=2, ls='--')
    ax0.set_title(f'{dv}: {label}', fontsize=8.5, fontweight='bold', color=C_DARK)
    ax0.set_ylabel('Densidad', fontsize=8)
    ax0.text(0.97, 0.93, f'No IA \nμ={g0.mean():.2f}',
            ha='right', va='top', transform=ax0.transAxes,
            fontsize=8, color=C_DARK,
            bbox=dict(boxstyle='round,pad=0.3', facecolor=C_LIGHT, alpha=0.7))
    ax0.spines['top'].set_visible(False); ax0.spines['right'].set_visible(False)

    # Bottom row: IA users
    ax1 = axes[1, j]
    ax1.hist(g1, bins=bins, color=C_DARK, alpha=0.85, edgecolor='white', density=True)
    ax1.axvline(g1.mean(), color=C_RED, lw=2, ls='--')
    ax1.set_xlabel('Valor (escala invertida)', fontsize=8)
    ax1.set_ylabel('Densidad', fontsize=8)
    ax1.text(0.97, 0.93, f'IA gen. \nμ={g1.mean():.2f}',
            ha='right', va='top', transform=ax1.transAxes,
            fontsize=8, color=C_WHITE,
            bbox=dict(boxstyle='round,pad=0.3', facecolor=C_DARK, alpha=0.8))

```

```

ax1.spines['top'].set_visible(False); ax1.spines['right'].set_visible(False)

handles_f34 = [mpatches.Patch(color=C_LIGHT,label='No usa IA (fila superior)'),
               mpatches.Patch(color=C_DARK, label='Usa IA generativa (fila inferior)')]
fig.legend(handles=handles_f34, loc='lower center', ncol=2, fontsize=8.5,
           bbox_to_anchor=(0.5,-0.02), framealpha=0.9)
fig.text(0.5,-0.04,
        'Líneas discontinuas = medias de grupo. DVs invertidas: D1/D5 ↑ = mejor WLB; D2/D3/D4
↑ = peor WLB. '
        'Fuente: EWCS 2024/25 (Eurofound).',
        ha='center', fontsize=8, color=C_GREY)
plt.tight_layout(rect=[0,0.04,1,0.96])
plt.savefig(os.path.join(OUTPUT_DIR,'Fig3_4_Distribuciones_DVs.png'),
            dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(" Fig3_4_Distribuciones_DVs.png guardada")

print(" Análisis descriptivo completado.")

# =====
# 4. CORRELACIONES DE SPEARMAN - FIGURA 3.5
# =====
# Se usa Spearman (no Pearson) porque las DVs son variables ordinales.
# Tres paneles: controles+DV, moderadores+DV, DVs entre sí+IA.

print("\n4. Correlaciones de Spearman...")

def spearman_matrix(data, vars_list):
    sub = data[vars_list].dropna()
    k = len(vars_list)
    rho_mat = np.zeros((k,k)); p_mat = np.ones((k,k))
    for i,v1 in enumerate(vars_list):
        for j,v2 in enumerate(vars_list):
            if i!=j:
                rho,p = stats.spearmanr(sub[v1],sub[v2])
                rho_mat[i,j]=rho; p_mat[i,j]=p
            else:
                rho_mat[i,j]=1.0
    return pd.DataFrame(rho_mat,index=vars_list,columns=vars_list), p_mat, len(sub)

# — Mapa de etiquetas para Figura 3.5 y Tabla 3.3 —————
LABEL_MAP_FIG = {
    'D1': 'D1: Encaje WLB',
    'D2': 'D2: Interf. temporal',
    'D3': 'D3: Fuera horario',
    'D4': 'D4: Interf. tensión',
    'D5': 'D5: Predic. horario',
    'genai_dummy': 'IA generativa',
    'female': 'Mujer',
    'age': 'Edad',
    'edu_high': 'Educ. alta',
    'hours_week': 'Horas semanales',
    'sme': 'Pyme',
    'telework_inv': 'Teletrabajo',
    'autonomy_idx': 'Autonomía',
    'intensity_idx': 'Intensidad laboral',
}

def rename_for_plot(data, vars_list):
    """Devuelve un DataFrame con columnas renombradas según LABEL_MAP_FIG."""
    renamed = {v: LABEL_MAP_FIG.get(v, v) for v in vars_list}
    return data[vars_list].rename(columns=renamed), list(renamed.values())

corr_groups = [
    (['D1','genai_dummy','female','age','edu_high','hours_week','sme'],
     'A) Controles + DV'),
    (['D1','genai_dummy','telework_inv','autonomy_idx','intensity_idx'],
     'B) Moderadores + DV'),
    (['D1','D2','D3','D4','D5','genai_dummy'],
     'C) Dimensiones WLB + IA'),
]

fig, axes = plt.subplots(1,3, figsize=(18,6), facecolor=C_WHITE)
fig.suptitle('Figura 3.5. Matrices de correlación de Spearman (triángulo inferior)',
             fontsize=11, fontweight='bold', color=C_DARK)

```

```

for ax, (var_group, title) in zip(axes, corr_groups):
    df_renamed, renamed_vars = rename_for_plot(df, var_group)
    rho, pvals, n = spearman_matrix(df_renamed, renamed_vars)
    var_group = renamed_vars # use labels for axis ticks
    mask = np.triu(np.ones_like(rho, dtype=bool), k=1)
    sns.heatmap(rho, ax=ax, mask=mask, annot=True, fmt='.2f',
                cmap='RdBu_r', center=0, vmin=-1, vmax=1,
                linewidths=0.5, linecolor='#EEEEEE',
                annot_kws={'size':8}, cbar=(ax==axes[-1]))
    for i in range(len(var_group)):
        for j in range(len(var_group)):
            if i>j:
                p=pvals[i,j]
                s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else ''))
                if s:
                    ax.text(j+0.5, i+0.75, s, ha='center', va='center',
                            fontsize=6, color='black', fontweight='bold')
    ax.set_title(f'{title}\n(N={n:,})', fontsize=10)
    ax.tick_params(axis='x', rotation=45, labelsz=8)
    ax.tick_params(axis='y', rotation=0, labelsz=8)

fig.text(0.5, -0.01,
        '* p<0,05 ** p<0,01 *** p<0,001. Fuente: EWCS 2024/25 (Eurofound).',
        ha='center', fontsize=8, color=C_GREY)
plt.tight_layout()
plt.savefig(os.path.join(OUTPUT_DIR, 'Fig3_5_Correlaciones_Spearman.png'),
            dpi=180, bbox_inches='tight', facecolor=C_WHITE)
plt.close()
print(" Fig3_5_Correlaciones_Spearman.png guardada")

# =====
# 5. TEST VIF - TABLA 3.3
# =====
# VIF < 5 = aceptable. Excepción documentada: edad/edad² VIF~45 (mecánico).
# genai_dummy VIF~1,2 → prácticamente ortogonal al resto → coeficientes limpios.

print("\n5. Test VIF (Tabla 3.3)...")

vif_vars = ['genai_dummy', 'telework_z', 'autonomy_z', 'intensity_z',
            'female', 'age', 'age2', 'edu_med', 'edu_high',
            'hours_week', 'sme', 'employee_selfdeclared_bin']
vif_sub = df[[v for v in vif_vars if v in df.columns]].dropna()
X_vif = sm.add_constant(vif_sub)

VIF_LABELS = {
    'genai_dummy': 'Uso de IA generativa',
    'telework_z': 'Teletrabajo (z)',
    'autonomy_z': 'Autonomía laboral (z)',
    'intensity_z': 'Intensidad laboral (z)',
    'female': 'Mujer',
    'age': 'Edad',
    'age2': 'Edad²',
    'edu_med': 'Educación media',
    'edu_high': 'Educación alta',
    'hours_week': 'Horas semanales',
    'sme': 'Pyme (<=249 emp.)',
    'employee_selfdeclared_bin': 'Asalariado',
}

vif_data = []
for i, v in enumerate(X_vif.columns):
    if v != 'const':
        vf = variance_inflation_factor(X_vif.values, i)
        nota = 'Mecánico (par edad/edad²)' if vf > 10 else 'Aceptable (<5)'
        vif_data.append({'Variable': VIF_LABELS.get(v, v), 'VIF': f"{vf:.2f}",
            'Interpretación': nota})

df_33 = pd.DataFrame(vif_data).sort_values('VIF', ascending=False)
table_to_png(
    df_33,
    'Tabla3_3_VIF.png',
    f'Tabla 3.3. Test VIF - Factor de Inflación de la Varianza '
    f'(N={len(vif_sub):,}) casos completos). Fuente: EWCS 2024/25. Elaboración propia.',
    figsize=(10, 5.5),
    fontsize=9,
)

```

```

)
print(f"    N para VIF: {len(vif_sub):,}")

# =====
# 6. MODELOS OLS STEPWISE - TABLAS 4.x Y FIGURA 4.1
# =====

print("\n6. Estimando modelos OLS stepwise...")

CONTROLS = (['female', 'age', 'age2', 'edu_med', 'edu_high',
            'hours_week', 'sme', 'employee_selfdeclared_bin'] +
            isco_cols + nace_cols + ctry_cols)
MAIN_IV   = ['genai_dummy']
MODERATORS = ['telework_z', 'autonomy_z', 'intensity_z']
INTERACT_ALL = ['genai_x_telework', 'genai_x_autonomy', 'genai_x_intensity']

ALL_VARS = (list(DVs.keys()) + MAIN_IV + MODERATORS +
            ['female', 'age', 'age2', 'edu_med', 'edu_high', 'hours_week',
            'sme', 'employee_selfdeclared_bin'] + INTERACT_ALL +
            isco_cols + nace_cols + ctry_cols)
ALL_VARS = [v for v in ALL_VARS if v in df.columns]
df_model = df[ALL_VARS].dropna()
print(f"    N casos completos (muestra modelo): {len(df_model):,}")
print(f"    Adopción IA en muestra modelo: {df_model['genai_dummy'].mean()*100:.1f}%")

def run_ols(data, dv, regressors):
    """OLS con errores estándar robustos HC3."""
    regs_ok = [r for r in regressors if r in data.columns]
    sub = data[[dv]+regs_ok].dropna()
    X = sm.add_constant(sub[regs_ok]); y = sub[dv]
    return sm.OLS(y, X).fit(cov_type='HC3'), len(sub)

SPECS = {
    'M1'      : CONTROLS,
    'M2'      : CONTROLS + MAIN_IV + MODERATORS,
    'M3a'     : CONTROLS + MAIN_IV + MODERATORS + ['genai_x_telework'],
    'M3b'     : CONTROLS + MAIN_IV + MODERATORS + ['genai_x_autonomy'],
    'M3c'     : CONTROLS + MAIN_IV + MODERATORS + ['genai_x_intensity'],
    'M3full'  : CONTROLS + MAIN_IV + MODERATORS + INTERACT_ALL,
}

results = {}
for dv in DVs:
    results[dv] = {}
    for mname, regressors in SPECS.items():
        m, n = run_ols(df_model, dv, regressors)
        results[dv][mname] = (m, n)

# --- Tabla 4.1 resumen ---
print("\n    === Tabla 4.1 -  $\beta$  (GenAI) en M1, M2, M3full ===")
rows_41 = []
for dv in DVs:
    m1, _ = results[dv]['M1']
    m2, _ = results[dv]['M2']
    m3, _ = results[dv]['M3full']
    b2=m2.params['genai_dummy']; se2=m2.bse['genai_dummy']; p2=m2.pvalues['genai_dummy']
    b3=m3.params['genai_dummy']; p3=m3.pvalues['genai_dummy']
    s2='***' if p2<0.001 else ('**' if p2<0.01 else ('*' if p2<0.05 else 'n.s.'))
    s3='***' if p3<0.001 else ('**' if p3<0.01 else ('*' if p3<0.05 else 'n.s.'))
    print(f"    {dv}: M2  $\beta$ ={b2:+.4f}{s2} SE={se2:.4f} | R2M1={m1.rsquared:.3f} "
          f"R2M2={m2.rsquared:.3f} R2M3={m3.rsquared:.3f}")
    rows_41.append({
        'DV':      f"{dv}: {DVs[dv]}",
        'R2 M1':  f"{m1.rsquared:.3f}",
        ' $\beta$  M2':  f"{b2:+.3f}{s2}",
        'SE M2':   f"{se2:.3f}",
        'R2 M2':  f"{m2.rsquared:.3f}",
        ' $\beta$  M3full': f"{b3:+.3f}{s3}",
        'R2 M3':  f"{m3.rsquared:.3f}",
    })

df_41 = pd.DataFrame(rows_41)
table_to_png(
    df_41,
    'Tabla4_1_Resumen_Coeficientes.png',
    f'Tabla 4.1. Coeficiente  $\beta$  (IA generativa) en M1, M2 y M3 completo por dimensión WLB. '

```

```

f'N={len(df_model):,}. HC3. Fuente: EWCS 2024/25.',
figsize=(14, 3.5),
fontsize=9,
)

# — Tablas 4.2-4.6 – Resultados detallados por dimensión (sin título en PNG) —
# El título aparece en el documento Word; el PNG se genera sin encabezado.

KEY_VARS = [
    ('genai_dummy',          'IA generativa'),
    ('telework_z',          'Teletrabajo (z)'),
    ('autonomy_z',          'Autonomía (z)'),
    ('intensity_z',         'Intensidad (z)'),
    ('genai_x_telework',    'IA × Teletrabajo'),
    ('genai_x_autonomy',    'IA × Autonomía'),
    ('genai_x_intensity',   'IA × Intensidad'),
    ('female',              'Mujer'),
    ('age',                  'Edad'),
    ('edu_med',              'Educ. media'),
    ('edu_high',             'Educ. alta'),
    ('hours_week',          'Horas semanales'),
    ('sme',                  'Pyme (<249 emp)'),
    ('employee_selfdeclared_bin', 'Asalariado'),
]

TABLE_NUMS = {'D1': '4_2', 'D2': '4_3', 'D3': '4_4', 'D4': '4_5', 'D5': '4_6'}

for dv, label in DVs.items():
    m1, n1 = results[dv]['M1']
    m2, n2 = results[dv]['M2']
    m3, n3 = results[dv]['M3full']
    rows_det = []
    for var, vlabel in KEY_VARS:
        row = {'Variable': vlabel}
        for mname, m, n in [('M1', m1, n1), ('M2', m2, n2), ('M3full', m3, n3)]:
            if var in m.params.index:
                b = m.params[var]; se = m.bse[var]; p = m.pvalues[var]
                s = '***' if p < 0.001 else '**' if p < 0.01 else '*' if p < 0.05 else ''
                row[mname] = f"{b:+.3f}{s}\n({se:.3f})"
            else:
                row[mname] = '-'
        rows_det.append(row)
    rows_det.append({'Variable': 'R²',
                    'M1': f"{m1.rsquared:.3f}",
                    'M2': f"{m2.rsquared:.3f}",
                    'M3full': f"{m3.rsquared:.3f}"})
    rows_det.append({'Variable': 'N',
                    'M1': f"{n1:,}", 'M2': f"{n2:,}", 'M3full': f"{n3:,}"})
    df_det = pd.DataFrame(rows_det)
    tnum = TABLE_NUMS[dv]
    fname = f"Tabla{tnum}_{dv}_Detalle.png"
    # — No title in PNG: título lo pone el Word —
    nr, nc = df_det.shape
    fig, ax = plt.subplots(figsize=(11, 6.5), facecolor=C_WHITE)
    ax.axis('off')
    tbl_plot = ax.table(cellText=df_det.values, colLabels=df_det.columns,
                       cellLoc='center', loc='center')
    tbl_plot.auto_set_font_size(False)
    tbl_plot.set_fontsize(8.5)
    tbl_plot.scale(1, 1.6)
    for j in range(nc):
        cell = tbl_plot[0, j]
        cell.set_facecolor(C_DARK)
        cell.set_text_props(color='white', fontweight='bold')
    for i in range(1, nr + 1):
        bg = '#F2F7FC' if i % 2 == 0 else C_WHITE
        for j in range(nc):
            tbl_plot[i, j].set_facecolor(bg)
            tbl_plot[i, j].set_edgecolor('#DDDDDD')
    # Título mínimo: solo la dimensión (para identificar el PNG al pegarlo en Word)
    dv_short_titles = {
        'D1': 'D1: Encaje global WLB',
        'D2': 'D2: Interferencia tiempo-familia',
        'D3': 'D3: Trabajo fuera de horario',
        'D4': 'D4: Interferencia por tensión',
        'D5': 'D5: Predicibilidad del horario',
    }

```

```

    }
    ax.set_title(dv_short_titles.get(dv, dv), fontsize=9, fontweight='bold',
                color='#1F3864', loc='left', pad=4)
    plt.tight_layout()
    plt.savefig(os.path.join(OUTPUT_DIR, fname), dpi=180,
                bbox_inches='tight', facecolor=C_WHITE)
    plt.close()

# --- Tabla 4.7 interacciones -----
print("\n === Interacciones M3full ===")
rows_47 = []
for dv in DVs:
    m3,_ = results[dv]['M3full']
    row = {'DV': f"{dv}: {DVs[dv]}"}
    for iv,label in [('genai_x_telework','×Teletrabajo'),
                    ('genai_x_autonomy','×Autonomía'),
                    ('genai_x_intensity','×Intensidad')]:
        if iv in m3.params.index:
            b=m3.params[iv]; se=m3.bse[iv]; p=m3.pvalues[iv]
            s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else 'n.s.))'
            row[label] = f"{b:+.3f}{s}"
            print(f" {dv} {label}: β={b:+.4f}{s}")
        else:
            row[label] = '-'
    rows_47.append(row)

df_47 = pd.DataFrame(rows_47)
table_to_png(
    df_47,
    'Tabla4_7_Interacciones.png',
    f'Tabla 4.7. Efectos de interacción IA×moderadores (M3 completo). '
    f'HC3. N={len(df_model):}. * p<0,05 ** p<0,01 *** p<0,001.',
    figsize=(12, 3.5),
    fontsize=9,
)

# --- Figura 4.1 -----
dv_list = list(DVs.keys())
x = np.arange(len(dv_list))
dv_labels_fig = {
    'D1':'D1: Encaje\nglobal WLB', 'D2':'D2: Interf.\ntemporal',
    'D3':'D3: Trabajo\nfuera horario', 'D4':'D4: Interf.\npor tensión',
    'D5':'D5: Predic.\nhorario',
}

fig, axes = plt.subplots(2,1, figsize=(14,10), facecolor=C_WHITE)
fig.suptitle('Figura 4.1. Coeficientes de IA generativa y términos de interacción',
            fontsize=12, fontweight='bold', color=C_DARK, y=0.98)

# Panel A
ax = axes[0]; ax.set_facecolor('#FAFAFA')
ax.axhline(0, color='#333333', lw=1.2, ls='--', alpha=0.7)
for offset,mname,color,label in [(-0.2,'M2',C_MID,'M2: Efecto directo'),
                                (+0.2,'M3full',C_DARK,'M3 completo')]:
    betas,ci_lo,ci_hi,pvals = [],[],[],[]
    for dv in dv_list:
        m,_ = results[dv][mname]
        if 'genai_dummy' in m.params.index:
            b=m.params['genai_dummy']; se=m.bse['genai_dummy']
            betas.append(b); ci_lo.append(b-1.96*se)
            ci_hi.append(b+1.96*se); pvals.append(m.pvalues['genai_dummy'])
        else:
            betas.append(np.nan); ci_lo.append(np.nan)
            ci_hi.append(np.nan); pvals.append(1)
    betas=np.array(betas); ci_lo=np.array(ci_lo)
    ci_hi=np.array(ci_hi); pvals=np.array(pvals)
    xpos=x+offset
    ax.errorbar(xpos,betas,yerr=[betas-ci_lo,ci_hi-betas],
                fmt='none',color=color,capsize=5,lw=1.5,alpha=0.8)
    for j,(xp,b,p) in enumerate(zip(xpos,betas,pvals)):
        if np.isnan(b): continue
        mk='D' if offset<0 else 'S'
        if p<0.05: ax.plot(xp,b,marker=mk,color=color,ms=9,zorder=5)
        else: ax.plot(xp,b,marker=mk,color='white',ms=9,
                    markeredgewidth=2,zorder=5)
        s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else ''))
        if s: ax.text(xp,ci_hi[j]+0.005,s,ha='center',fontsize=9,

```

```

        color=color,fontweight='bold')

ax.set_xticks(x); ax.set_xticklabels([dv_labels_fig[d] for d in dv_list],fontsize=9.5)
ax.set_ylabel('β (IA generativa)',fontsize=9.5)
ax.set_title('A) Efecto directo de IA generativa (M2 vs. M3 completo)',
            fontsize=10,loc='left')
ax.legend(handles=[mpatches.Patch(color=C_MID,label='M2'),
                  mpatches.Patch(color=C_DARK,label='M3 completo')],
          fontsize=8.5,framealpha=0.9)
ax.grid(axis='y',alpha=0.4)
ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)

# Panel B
ax = axes[1]; ax.set_facecolor('#FAFAFA')
ax.axhline(0,color='#333333',lw=1.2,ls='--',alpha=0.7)
INTERACT_VARS = [('genai_x_telework','#2E75B6','× Teletrabajo',-0.3),
                 ('genai_x_autonomy','#ED7D31','× Autonomía', 0.0),
                 ('genai_x_intensity','#C00000','× Intensidad', +0.3)]
for iv,color,label,offset in INTERACT_VARS:
    betas,ci_lo,ci_hi,pvals=[],[],[],[]
    for dv in dv_list:
        m,_ = results[dv]['M3full']
        if iv in m.params.index:
            b=m.params[iv]; se=m.bse[iv]
            betas.append(b); ci_lo.append(b-1.96*se)
            ci_hi.append(b+1.96*se); pvals.append(m.pvalues[iv])
        else:
            betas.append(np.nan); ci_lo.append(np.nan)
            ci_hi.append(np.nan); pvals.append(1)
    betas=np.array(betas); ci_lo=np.array(ci_lo)
    ci_hi=np.array(ci_hi); pvals=np.array(pvals)
    xpos=x+offset
    ax.errorbar(xpos,betas,yerr=[betas-ci_lo,ci_hi-betas],
                fmt='none',color=color,capsize=5,lw=1.5,alpha=0.8)
    for j,(xp,b,p) in enumerate(zip(xpos,betas,pvals)):
        if np.isnan(b): continue
        if p<0.05: ax.plot(xp,b,marker='o',color=color,ms=9,zorder=5)
        else:      ax.plot(xp,b,marker='o',color='white',ms=9,
                            markeredgewidth=2,zorder=5)
        s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else ''))
        if s: ax.text(xp,ci_hi[j]+0.004,s,ha='center',fontsize=9,
                    color=color,fontweight='bold')

ax.set_xticks(x); ax.set_xticklabels([dv_labels_fig[d] for d in dv_list],fontsize=9.5)
ax.set_ylabel('β (término interacción)',fontsize=9.5)
ax.set_title('B) Efectos moderadores (M3 completo)',fontsize=10,loc='left')
ax.legend(handles=[mpatches.Patch(color=c,label=l) for _,c,l,_ in INTERACT_VARS],
          fontsize=8.5,framealpha=0.9)
ax.grid(axis='y',alpha=0.4)
ax.spines['top'].set_visible(False); ax.spines['right'].set_visible(False)

fig.text(0.5,0.005,
        f'Puntos rellenos: p<0,05. IC 95%. DVs invertidas: D1/D5 β+ = mejor WLB; D2/D3/D4 β+ = peor WLB. '
        f'N={len(df_model):}. Fuente: EWCS 2024/25.',
        ha='center',fontsize=8,color=C_GREY)
plt.tight_layout(rect=[0,0.02,1,0.96])
plt.savefig(os.path.join(OUTPUT_DIR,'Fig4_1_Coeficientes_GenAI.png'),
            dpi=200,bbox_inches='tight',facecolor=C_WHITE)
plt.close()
print("\n Fig4_1_Coeficientes_GenAI.png guardada")

# =====
# 7. PRUEBAS DE ROBUSTEZ
# =====

print("\n7. Pruebas de robustez...")

# 7.1 Sensitivity con permanent
print("\n 7.1 Sensitivity con 'permanent':")
for dv in ['D1','D2','D4']:
    for mname,regressors in [('M2_perm', CONTROLS+['permanent']+MAIN_IV+MODERATORS),
                            ('M3_perm',
                             CONTROLS+['permanent']+MAIN_IV+MODERATORS+INTERACT_ALL)]:
        m,n = run_ols(df,dv,regressors)
        if 'genai_dummy' in m.params.index:

```

```

        b=m.params['genai_dummy']; se=m.bse['genai_dummy']; p=m.pvalues['genai_dummy']
        s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else 'n.s.'))
        print(f"      {dv} {mname}:  $\beta$ ={b:+.4f}{s} (SE={se:.4f}), N={n:,}")

# 7.2 D2 alternativo
print("\n 7.2 D2 alternativo (freetime_work + contact_out_wh):")
if 'contact_out_wh' in df.columns:
    df['contact_inv'] = clean_invert(df['contact_out_wh'], 5)
    df['D3_idx'] = df[['D3','contact_inv']].mean(axis=1)
    df_model = df_model.copy()
    df_model['D3_idx'] = df.loc[df_model.index,'D3_idx']
    m_alt,n_alt = run_ols(df_model,'D3_idx',CONTROLS+MAIN_IV+MODERATORS)
    if 'genai_dummy' in m_alt.params.index:
        b=m_alt.params['genai_dummy']; se=m_alt.bse['genai_dummy'];
        p=m_alt.pvalues['genai_dummy']
        s='***' if p<0.001 else ('**' if p<0.01 else ('*' if p<0.05 else 'n.s.'))
        print(f"      D3_idx M2:  $\beta$ ={b:+.4f}{s} (SE={se:.4f}), N={n_alt:,}")
        print(f"      Comparar con D3 base  $\beta$ =+0,133*** - robustez OK si mismo signo y sig.")
    else:
        print("      contact_out_wh no disponible.")

print("\n" + "="*70)
print(" ANÁLISIS COMPLETADO - TODOS LOS ARCHIVOS GENERADOS:")
outputs = sorted(os.listdir(OUTPUT_DIR))
for f in outputs:
    size = os.path.getsize(os.path.join(OUTPUT_DIR,f))
    print(f" {f} ({size/1024:.0f} KB)")
print("="*70)

```