



Universidad Pontificia Comillas
Facultad de Ciencias Económicas y Empresariales

Grado en Business Analytics

El uso de la IA en el lugar de trabajo: datos de la Encuesta Europea sobre las Condiciones de Trabajo 2024

Autor: Pablo Martín Huidobro
Director: María Jesús Belizón Cebada

ÍNDICE

1. Introducción.....	3
1.1. Objetivo del Trabajo.....	6
1.2. Preguntas de Investigación	6
2. Revisión de la Literatura y Desarrollo de la Hipótesis.....	7
2.1. El esfuerzo y la intensificación del trabajo.....	7
2.2. El impacto de la adopción de la IA en la intensificación del trabajo	9
3. Metodología.....	13
3.1. Fuente de datos y diseño de la muestra	13
3.2. Definición y estadísticos descriptivos de las variables.....	14
3.3. Estrategia empírica y análisis computacional en R	16
4. Análisis de resultados	18
4.1. Estadísticos descriptivos: adopción de la IA en Europa (PdI 1).....	18
4.2. Análisis de correlaciones de Spearman	22
4.3. El modelo de regresión completo	24
4.4. Efecto de la IA sobre el esfuerzo intensivo (H1a).....	27
4.5. Efecto de la IA sobre la salud y el bienestar (H1b).....	27
4.6. Efecto asimétrico por género (H2)	29
4.7. Efecto moderador de los intereses laborales (H3).....	29
4.8. Las variables de control.....	30
4.9. Síntesis de hipótesis.....	31
5. Discusión y conclusión.....	32
6. Implicaciones prácticas.....	35
6.1. Implicaciones para políticas públicas	36
6.2. Implicaciones para las organizaciones	38
7. Bibliografía.....	40

1. INTRODUCCIÓN

La situación macroeconómica global actual está pasando por un proceso de cambio estructural bastante grande, impulsado en gran medida por el rápido avance de la Inteligencia Artificial (IA) y de las tecnologías de automatización avanzada dentro de los sistemas productivos. Tal como señala la Organización para la Cooperación y el Desarrollo Económicos (OCDE) en su informe *Employment Outlook 2023*, el crecimiento acelerado de estas herramientas, sobre todo la aparición de la IA generativa y la reducción sustancial en los costes necesarios para adoptar estas nuevas tecnologías está situando a muchas economías desarrolladas en la antesala de lo que podríamos llegar a considerar una nueva revolución industrial.¹ Este proceso tiene el potencial de modificar de manera significativa la forma en la que actualmente entendemos el trabajo y la organización de los entornos laborales.

A diferencia de las etapas anteriores de automatización que vivimos a lo largo de las últimas décadas, las cuales afectaron principalmente a tareas de trabajo manual y repetitivas del sector industrial, la Inteligencia Artificial actualmente posee capacidades técnicas mucho más amplias. En especial, puede llegar a realizar funciones cognitivas, analíticas y no siempre rutinarias, lo que indica que su impacto no solo se limita a un tipo concreto de empleo, sino que se extiende de forma transversal a prácticamente todos los sectores del mercado laboral, incluyendo también algunas profesiones altamente cualificadas dentro del sector servicios.

Desde el punto de vista macroeconómico, muchas de las predicciones realizadas por instituciones mantienen un enfoque relativamente optimista con relación a los posibles beneficios que la IA podría traernos en términos de crecimiento y eficiencia económica. Algunas de las últimas investigaciones dan a entender que la adopción generalizada de la IA generativa podría contribuir a aumentar la productividad total de los factores y llegar a ocasionar un incremento del Producto Interior Bruto (PIB) estadounidense cercano al 1,5% para el año 2035.² Siguiendo esta misma línea, existen estudios empíricos realizados por la Reserva Federal de San Luis (St. Louis) en 2025 que indican que el uso avanzado de herramientas de IA generativa ya permite a muchos trabajadores ahorrarse alrededor del

¹ OCDE (2023). *OECD Employment Outlook 2023: Artificial intelligence and the labour market*. OECD Publishing, París. <https://doi.org/10.1787/08785bba-en>

² Penn Wharton Budget Model (2025). *The projected impact of generative AI on future productivity growth*. University of Pennsylvania. <https://budgetmodel.wharton.upenn.edu/p/2025-09-08-the-projected-impact-of-generative-ai-on-future-productivity-growth/>

5,4% de su tiempo de trabajo semanal, lo que se traduce en un incremento aproximado del 1,1% en la productividad a nivel nacional.³

Por otro lado, dentro del contexto de la situación de la economía laboral actual, este posible beneficio tecnológico no se produce de forma aislada ni se encuentra libre de tensiones. La llegada e introducción de la Inteligencia Artificial dentro de las organizaciones suele funcionar como una fuerza que actúa en dos direcciones al mismo tiempo. Por un lado, permite optimizar y acelerar procesos, agilizar tareas y gestionar grandes cantidades de información con mayor velocidad. Sin embargo, a su vez también introduce nuevas formas de presión y control sobre los trabajadores. Según datos recientemente publicados por el Centro Común de Investigación (JRC) de la Comisión Europea en 2025, aproximadamente en torno al 30% de los trabajadores de la Unión Europea ya utiliza distintas herramientas de IA de manera habitual en su actividad laboral.⁴ No obstante, esta rápida integración tecnológica también está relacionada con el crecimiento de lo que actualmente conocemos como gestión algorítmica. El mismo informe del JRC señala que en torno al 37% de los empleados afirma que sus empresas utilizan estos sistemas digitales basados en IA para monitorizar de forma constante sus horas de trabajo y su ritmo de actividad, y cerca del 24% ha indicado que su actividad laboral depende de sistemas automatizados que asignan tareas o establecen horarios de manera completamente automática.

Este nivel elevado de configuración del entorno laboral tiene como objetivo principal maximizar la eficiencia y la rentabilidad dentro de las empresas. Sin embargo, tal como ya han advertido diversos estudios académicos y la propia Comisión Europea, en muchos casos esta búsqueda de la eficiencia puede llegar a tener efectos negativos sobre los trabajadores. Entre estos se encuentran el aumento del estrés laboral, la reducción notable del grado de autonomía dentro del trabajo y una intensificación de los ritmos y la carga de trabajo. Cuando este esfuerzo intensivo se prolonga en el tiempo, puede derivar en consecuencias observables sobre la salud física y psicosocial de los trabajadores, como ansiedad, dificultades para conciliar el sueño, problemas musculoesqueléticos o un deterioro de la salud general autopercebida.

³ Bick, A., Blandin, A. y Deming, D. (2025). *The impact of generative AI on work productivity*. Federal Reserve Bank of St. Louis (On the Economy). <https://www.stlouisfed.org/on-the-economy/2025/feb/impact-generative-ai-work-productivity>

⁴ Gonzalez-Vazquez, I., Fernández-Macías, E., Wright, S. y Villani, D. (2025). *Digital monitoring, algorithmic management and the platformisation of work in Europe*. Joint Research Centre (JRC143072), Comisión Europea. <https://publications.jrc.ec.europa.eu/repository/handle/JRC143072>

En este contexto, los primeros resultados de la Encuesta Europea sobre las Condiciones de Trabajo (EWCS) de 2024, coordinada por la agencia Eurofound, nos ofrecen información relevante.⁵ Aunque aproximadamente el 12% de la fuerza laboral de la Unión Europea ya está utilizando herramientas de IA generativa en sus tareas, los datos de la EWCS 2024 muestran una tendencia preocupante: en muchos casos estas nuevas tecnologías se asocian con más exigencias y nuevas responsabilidades de las que realmente eliminan. Adicionalmente, los indicadores elaborados por Eurofound muestran que la intensidad del trabajo volvió a aumentar durante 2024 después de varios años de relativa estabilidad, afectando de forma especialmente significativa a las mujeres y a aquellas personas que desempeñan trabajos con altas demandas emocionales.

Ante todas estas transformaciones, las instituciones europeas han comenzado a responder mediante la creación de un marco regulatorio pionero a nivel internacional. Un ejemplo claro es la reciente entrada en vigor del AI Act (Reglamento (UE) 2024/1689)⁶, que clasifica como sistemas de alto riesgo a aquellas herramientas de IA destinadas a la gestión del rendimiento de los trabajadores, los procesos de contratación o el análisis de recursos humanos, reflejando la preocupación de los legisladores europeos por evitar que la expansión de los sistemas algorítmicos genere una vigilancia excesiva de los empleados, sesgos discriminatorios o un deterioro progresivo de las condiciones laborales.

Dentro de un entorno macroeconómico y regulatorio que continúa evolucionando rápidamente, resulta muy importante evitar una visión excesivamente reduccionista de la tecnología. No debemos asumir que la adopción de herramientas de Inteligencia Artificial producirá automáticamente efectos positivos o negativos, sino que es necesario evaluar de manera minuciosa cómo interactúa con los factores sociales, económicos y organizativos. Entender estos efectos con mayor detalle permitirá a investigadores, políticos y directivos de empresas desarrollar estrategias que favorezcan entornos laborales más productivos, justos y sostenibles a largo plazo.

⁵ Eurofound (2026b). *European Working Conditions Survey 2024: Overview report*. Eurofound, Dublín. <https://www.eurofound.europa.eu/en/publications/all/european-working-conditions-survey-2024-overview-report>

⁶ Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial (Reglamento de Inteligencia Artificial). DOUE L, de 12 de julio de 2024. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj?locale=es>

1.1. Objetivo del Trabajo

El objetivo principal de este trabajo de investigación consiste en analizar de qué maneras el uso de la inteligencia artificial dentro del entorno de trabajo está influyendo en las condiciones laborales de los trabajadores europeos. En concreto, el estudio se centra en dos dimensiones complementarias: por un lado, el nivel de esfuerzo intensivo que los trabajadores perciben en su trabajo diario, medido a través de indicadores como el ritmo elevado de trabajo, los plazos ajustados y el estrés laboral; y por otro, la salud física y psicosocial de los empleados, que la literatura asocia a un esfuerzo intensivo sostenido en el tiempo. Todo ello se analiza en función del grado en que los trabajadores están expuestos a distintas formas de tecnología digital: la IA generativa, las plataformas de cooperación digital y los robots colaborativos.

Para poder llevar a cabo este objetivo, el trabajo utiliza un enfoque basado en el análisis estadístico de los datos procedentes de la Encuesta Europea sobre las Condiciones de Trabajo (EWCS) de 2024, coordinada por Eurofound. Esta base de datos ofrece una fuente de información muy completa que permite identificar y medir patrones generales en las condiciones de trabajo a nivel europeo. A partir de estos microdatos, se estudiará cómo la exposición a nuevas tecnologías puede influir en la organización del trabajo, en las presiones relacionadas con el tiempo y el ritmo de las tareas, y en la carga mental y física que experimentan los trabajadores.

Además, al analizar el grado de integración de estas nuevas tecnologías según los distintos sectores económicos y perfiles ocupacionales, este estudio tiene como fin ayudar a comprender mejor las posibles tensiones que pueden surgir entre la búsqueda continua de eficiencia operativa por parte de las empresas y la necesidad de mantener unas condiciones laborales adecuadas que preserven la calidad del trabajo y el bienestar de los empleados.

1.2. Preguntas de Investigación

Para definir claramente el objetivo general del trabajo, organizar el diseño metodológico y guiar la formulación de las hipótesis que posteriormente se analizarán de forma empírica, esta investigación se estructura alrededor de tres preguntas de investigación (PdI):

- ¿Cuál es el nivel de adopción de la inteligencia artificial en las empresas que operan en Europa?

- ¿De qué manera influye la exposición a tecnologías basadas en inteligencia artificial en el esfuerzo intensivo percibido y en la salud de los trabajadores europeos?
- ¿En qué medida ese efecto difiere según las características del trabajador; su género y los intereses laborales que prioriza, y qué otros factores del contexto laboral influyen en el esfuerzo y la salud?

Responder a estas tres preguntas no solo permitirá obtener una visión clara de la situación actual de la digitalización y el uso de la IA dentro de la Unión Europea, sino que también permitirá identificar qué elementos relacionados con la organización del trabajo pueden actuar como factores que reducen o suavizan la posible sobrecarga derivada de la introducción de estas nuevas tecnologías. La primera se responde mediante análisis descriptivo; la segunda, mediante los modelos de regresión estimados sobre las variables de esfuerzo intensivo y de salud (H1); y la tercera, mediante los términos de interacción que evalúan si ese efecto difiere por género (H2) y según los intereses laborales del trabajador (H3), junto al examen acotado del papel de las variables de control.

2. REVISIÓN DE LA LITERATURA Y DESARROLLO DE LA HIPÓTESIS

2.1. El esfuerzo y la intensificación del trabajo

Para ser capaces de analizar de manera correcta el impacto que puede llegar a tener una innovación tecnológica en el entorno laboral, primero es necesario definir con claridad qué entendemos exactamente por calidad del empleo. Según Geary y Wilson⁷, la calidad de un puesto de trabajo no se puede entender como una definición simple, sino que debemos tratarla como una realidad compleja y con muchas dimensiones. No es suficiente con fijarnos en aspectos económicos o externos del empleo, como el nivel salarial, el tipo de contrato o los beneficios económicos que ofrece. A pesar de que estos elementos sean importantes, no bastan por sí mismos para reflejar de manera completa cómo es realmente el entorno laboral.

⁷ Geary, J. y Wilson, L. (2023). *Job quality in Ireland*. Nevin Economic Research Institute (NERI). <https://www.neriinstitute.net/sites/default/files/research/Job%20quality%20in%20Ireland.pdf>

Por esta razón, los autores defienden que un empleo está compuesto por una combinación de distintos factores que deben analizarse mediante indicadores objetivos de dos grandes tipos. Por un lado, encontramos los indicadores económicos tradicionales como el salario, la estabilidad contractual o los beneficios materiales. Por otro lado, existen indicadores no económicos de carácter más intrínseco, relacionados con cómo se organiza el trabajo y con la experiencia que tienen los propios empleados dentro de su puesto. Estos indicadores surgen de la evaluación que realizan los propios empleados sobre aspectos como el grado de autonomía que poseen, las oportunidades para desarrollar nuevas habilidades, la forma en que se estructura su trabajo o el nivel de apoyo social que reciben dentro de la compañía.

Dentro de estos factores intrínsecos, el concepto del esfuerzo laboral y, sobre todo, la intensificación del trabajo ocupa un papel especialmente importante. La literatura académica especializada reconoce que el esfuerzo laboral no se trata de un término único, sino que presenta varias dimensiones. Por lo general, los estudios empíricos suelen dividirlo en dos componentes distintos pero relacionados entre sí: el esfuerzo extensivo y el esfuerzo intensivo.

El esfuerzo extensivo hace referencia principalmente al volumen total de horas que una persona dedica a su trabajo. Por regla general, se mide observando la duración de la jornada laboral y la frecuencia con la que los trabajadores realizan jornadas largas, lo que normalmente se considera trabajar más de 40 o incluso 48 horas semanales.

Por otro lado, el esfuerzo intensivo está relacionado con la intensidad o la presión bajo la que los empleados deben realizar sus tareas durante esas horas de trabajo. En este caso, lo que buscamos analizar no es cuánto tiempo se trabaja, sino en qué condiciones se desarrollan esas tareas: con qué frecuencia hay que trabajar a un ritmo muy elevado, si se están obligados a cumplir con plazos de entrega muy ajustados, o qué nivel de estrés perciben los trabajadores de manera habitual. Cuando esta intensificación es sostenida en el tiempo, sus efectos trascienden el plano puramente laboral y se manifiestan en forma de consecuencias observables sobre la salud física y psicosocial de los trabajadores, como pueden ser la ansiedad, las dificultades para conciliar el sueño, los problemas musculoesqueléticos o el deterioro de la salud autoevaluada de forma general. De hecho, la evidencia europea más reciente confirma que la intensidad del trabajo ha aumentado en las últimas décadas y que su magnitud depende en gran medida del contexto institucional de cada país: a partir de varias oleadas de la propia Encuesta Europea sobre las Condiciones de Trabajo, Adăscăliței

et al.⁸ muestran que la intensificación se acentuó tras la crisis económica, si bien la regulación del mercado laboral y la negociación colectiva pueden contenerla.

Para poder entender mejor cómo estas obligaciones afectan al bienestar de los trabajadores, tanto la psicología organizacional como la economía laboral han desarrollado algunos marcos teóricos que permiten analizar estas dinámicas. Uno de los modelos más reconocidos es el modelo de Demandas y Recursos del Trabajo (JD-R)⁹. La idea principal de este modelo defiende que cualquier puesto de trabajo está formado por dos grandes elementos: las demandas y los recursos. Las demandas incluyen todos los factores físicos, psicológicos o relacionados con el tiempo que exigen un esfuerzo para el trabajador; en cambio, los recursos son todos aquellos factores que ayudan a los trabajadores a afrontar esas demandas, como el grado de autonomía del que disponen, las oportunidades de aprendizaje o el apoyo de compañeros y superiores. De acuerdo con este modelo, cuando las demandas son elevadas y los recursos insuficientes, la situación puede derivar en alta tensión laboral con importantes consecuencias negativas tanto sobre el esfuerzo percibido como sobre la salud de los trabajadores.

Además de este modelo, otra de las teorías más importantes es la teoría del desequilibrio esfuerzo-recompensa (ERI), desarrollada por Siegrist.¹⁰ Este enfoque defiende que el estrés laboral aparece cuando existe un desequilibrio entre el esfuerzo percibido y la recompensa recibida. Cuando los empleados sienten que están realizando un esfuerzo muy elevado comparado con las recompensas que reciben, aparece un desequilibrio que puede identificarse como una de las principales fuentes de insatisfacción laboral, estrés y deterioro de la salud a largo plazo.

2.2. El impacto de la adopción de la IA en la intensificación del trabajo

La aparición de la Inteligencia Artificial y su introducción en los sistemas productivos puede entenderse como un cambio tecnológico con un gran impacto que está modificando la estabilidad que tradicionalmente ha existido entre el esfuerzo que llevan a cabo los empleados, las demandas de su trabajo y los recursos de los que disponen. Para analizar este acontecimiento de manera adecuada, hay que tener en cuenta los diferentes componentes

⁸ Adăscăliței, D., Heyes, J. y Mendonça, P. (2022). The intensification of work in Europe: A multilevel analysis. *British Journal of Industrial Relations*, 60(2), 324–347. <https://doi.org/10.1111/bjir.12611>

⁹ Bakker, A. B. y 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>

¹⁰ Siegrist, J. (1996). Adverse health effects of high-effort/low-reward conditions. *Journal of Occupational Health Psychology*, 1(1), 27–41. <https://doi.org/10.1037/1076-8998.1.1.27>

que constituyen este cambio: no solo la expansión de las herramientas de IA tanto generativa como analítica, sino también el desarrollo de lo que hoy conocemos como gestión algorítmica, así como la irrupción de herramientas de colaboración digital y robots colaborativos (cobots) en el entorno de trabajo.

Tal como señalan Gong et al.¹¹, la aparición y mejora de las distintas herramientas de inteligencia artificial han cambiado en gran medida la manera en que entendemos el trabajo, ocasionando un importante debate en el ámbito académico. Este debate se da alrededor de dos visiones contrapuestas. Por un lado, algunos autores consideran que la IA puede utilizarse como una herramienta transformadora que promueva una nueva etapa de crecimiento económico y mayor eficiencia. Sin embargo, también existe un enfoque más crítico que intenta alertar sobre los riesgos asociados a este proceso, sobre todo con respecto al aumento de la supervisión y vigilancia sobre los trabajadores o en relación con la posibilidad de que los algoritmos vayan asumiendo cada vez más funciones de control, lo que podría llegar a producir efectos negativos sobre el esfuerzo percibido y la salud y el bienestar de los empleados.

Uno de los cambios más relevantes producidos por este proceso de transformación es el crecimiento de la gestión algorítmica (ALMA), que probablemente representa uno de los elementos más invasivos en las labores diarias de los trabajadores. Este concepto se refiere a la utilización de sistemas digitales complejos o de inteligencia artificial para dirigir o evaluar a los trabajadores de una organización. En la práctica, esto significa que gran parte de las decisiones que antes eran tomadas por los responsables humanos ahora pasan a ser llevadas a cabo o supervisadas por estos algoritmos. Kellogg et al.¹² han conceptualizado este fenómeno como un nuevo «terreno en disputa» del control en el trabajo, en el que los algoritmos sirven para dirigir, evaluar y disciplinar a los empleados. Dentro de los mecanismos de dirección, los estudios suelen diferenciar dos tipos principales de control algorítmico: los algoritmos de restricción, que limitan la información disponible para el trabajador y establecen de forma rígida qué acciones se pueden realizar; y los algoritmos de orientación, que tan solo proporcionan recomendaciones basadas en el análisis automático de grandes bases de datos. Aunque en teoría ambos tipos han sido diseñados para mejorar la

¹¹ Gong, Q., Fan, D. y Bartram, T. (2025). Integrating artificial intelligence and human resource management: A review and future research agenda. *The International Journal of Human Resource Management*, 36(1), 103–141. <https://doi.org/10.1080/09585192.2024.2440065>

¹² Kellogg, K. C., Valentine, M. A. y Christin, A. (2020). Algorithms at work: The new contested terrain of control. *Academy of Management Annals*, 14(1), 366–410. <https://doi.org/10.5465/annals.2018.0174>

coordinación y la flexibilidad, sobre el terreno pueden acabar sometiendo a los empleados a sistemas de control poco transparentes, intensificando los ritmos de trabajo y reduciendo la autonomía de los trabajadores.

En paralelo a la gestión algorítmica, la adopción de plataformas de cooperación digital y la introducción de robots colaborativos (cobots) en entornos de trabajo físico están transformando también la naturaleza del esfuerzo y los ritmos de trabajo. Su uso se asocia con una mayor conectividad y disponibilidad esperada de los trabajadores, con una difuminación de los límites entre el tiempo de trabajo y el tiempo personal y con una mayor carga cognitiva, al requerir una atención sostenida y continua.

Si analizamos este fenómeno mediante el modelo de Demandas y Recursos del Trabajo (JD-R) y la teoría del Desequilibrio Esfuerzo-Recompensa (ERI), podemos ver cómo esta transformación tecnológica puede alterar el equilibrio que existe actualmente dentro del trabajo. Diversas investigaciones sugieren que el uso de la inteligencia artificial y de algoritmos para gestionar el trabajo puede asociarse con importantes presiones psicosociales sobre los empleados. Estas tecnologías tienden a relacionarse con mayores demandas del puesto y, al mismo tiempo, con menores recursos de los trabajadores, como la capacidad de tomar decisiones sobre su propio trabajo o el apoyo social dentro del entorno laboral. Según este marco, dicha dinámica se vincularía con un mayor esfuerzo intensivo percibido y, cuando se mantiene en el tiempo, con un peor estado de salud, que puede manifestarse en forma de ansiedad, dificultades para conciliar el sueño, dolores de cabeza, problemas musculoesqueléticos o un deterioro de la salud general autoevaluada. En este trabajo se adopta una posición definida dentro de este debate: se sostiene que la exposición a la IA, y de manera especial la coordinación algorítmica y las plataformas de cooperación digital, opera principalmente como una intensificación de las demandas laborales, y no como una ampliación de los recursos. Bajo el marco JD-R, esta lectura implica que estas tecnologías elevan el ritmo, los plazos y la supervisión a la vez que erosionan la autonomía del trabajador, lo que lleva a esperar una asociación positiva con el esfuerzo intensivo y, sostenida en el tiempo, negativa con la salud. Es precisamente esta relación la que el análisis somete a contraste.

Conviene añadir, además, que estos efectos psicosociales no tienen por qué distribuirse de manera homogénea entre toda la plantilla. La revisión de Gong et al.¹³ sobre la integración de la inteligencia artificial en la gestión de personas subraya que las consecuencias de estas tecnologías son heterogéneas y dependen de cómo los distintos colectivos las experimentan y responden ante ellas. En el caso de las mujeres, su mayor presencia en ocupaciones con altas demandas emocionales y de interacción social, unida a la denominada doble carga, laboral y doméstica, permite anticipar que la asociación adversa entre la IA y la salud sea más acusada en ellas que en los hombres.

Sin embargo, para poder ver la tecnología como un desafío y no como una amenaza, es necesario que existan recursos organizativos que ayuden a equilibrar esta situación. Algunos estudios han mostrado que determinados factores dentro de las organizaciones pueden desempeñar una función de escudo frente a los efectos negativos de la intensificación del trabajo. El estudio de Geary y Wilson¹⁴ ha demostrado que ciertos factores de carácter relacional e institucional pueden actuar como mecanismos de protección importantes. Ahora bien, más allá de la presencia objetiva de estos recursos en la organización, este trabajo se centra en un mecanismo distinto y complementario: los intereses laborales, entendidos como la importancia que cada trabajador concede a determinadas características de su empleo (la autonomía, una carga de trabajo manejable o la seguridad laboral), pueden modular la intensidad con la que experimenta los efectos adversos asociados a la tecnología. Esta idea conecta con la evidencia de Avgoustaki y Frankort¹⁵, quienes muestran que no toda intensidad laboral produce los mismos efectos: una misma intensidad de trabajo se asocia a niveles de bienestar muy distintos según los motivos y las prioridades del propio trabajador y el grado de autonomía que percibe. Cabe esperar, por tanto, que la asociación entre la exposición a la IA y el esfuerzo y la salud dependa de los intereses laborales de cada trabajador. El caso de la seguridad en el empleo merece atención particular. Desde la lógica del Desequilibrio Esfuerzo-Recompensa, para un trabajador que concede gran importancia a la estabilidad, una tecnología percibida como fuente de control externo e incertidumbre sobre su puesto amenaza directamente la recompensa que más valora: el desajuste entre el

¹³ Gong, Q., Fan, D. y Bartram, T. (2025). Integrating artificial intelligence and human resource management: A review and future research agenda. *The International Journal of Human Resource Management*, 36(1), 103–141. <https://doi.org/10.1080/09585192.2024.2440065>

¹⁴ Geary, J. y Wilson, L. (2023). *Job quality in Ireland*. Nevin Economic Research Institute (NERI). <https://www.nerininstitute.net/sites/default/files/research/Job%20quality%20in%20Ireland.pdf>

¹⁵ Avgoustaki, A. y Frankort, H. T. W. (2023). All work intensity is not created equal: Effort motives, job satisfaction and quit intentions at a grocery chain. *British Journal of Industrial Relations*, 61(4), 869–894. <https://doi.org/10.1111/bjir.12724>

esfuerzo que invierte y la seguridad que espera obtener se ensancha, y es esa brecha la que cabría esperar que se traduzca en mayor ansiedad.

Mediante la revisión de esta literatura y teniendo como referencia los modelos de estrés laboral mencionados anteriormente, este trabajo plantea las siguientes hipótesis:

H1: La exposición a la IA incrementa el esfuerzo percibido y deteriora la salud

La exposición a la IA en el trabajo (IA generativa, plataformas de cooperación digital y cobots) se relaciona positivamente con el esfuerzo intensivo percibido y con el deterioro de la salud. Es decir, a mayor exposición tecnológica: (a) mayor ritmo de trabajo, plazos más ajustados y estrés (H1a); y (b) mayor prevalencia de problemas de salud física y psicosocial, como ansiedad, dolores de cabeza, dolencias musculoesqueléticas, problemas de sueño y peor salud autopercebida (H1b).

H2: El deterioro de la salud asociado a la IA es mayor en las mujeres

La asociación adversa entre la IA y la salud es asimétrica por género: más intensa en las mujeres que en los hombres, especialmente en puestos con altas demandas emocionales o de interacción social, de modo que la interacción entre exposición tecnológica y sexo femenino se relaciona positivamente con el deterioro de la salud.

H3: Los intereses laborales moderan el efecto de la IA: la seguridad en el empleo lo amplifica

Los intereses laborales del trabajador moderan la asociación entre la IA y el esfuerzo y la salud. En particular, conforme a la teoría del Desequilibrio Esfuerzo-Recompensa, cuanto mayor es la importancia atribuida a la seguridad en el empleo, mayor sería la asociación adversa con la IA (interacción positiva con la ansiedad).

3. METODOLOGÍA

Para poner a prueba de forma rigurosa las hipótesis previamente descritas, este trabajo emplea un enfoque cuantitativo y analítico estructurado en torno al diseño y las variables proporcionadas por la encuesta europea. El proceso de preparación, limpieza y modelización de los datos se realizará íntegramente mediante el lenguaje de programación estadística R.

3.1. Fuente de datos y diseño de la muestra

La principal fuente de datos para llevar a cabo esta investigación son los microdatos correspondientes a la edición de 2024 de la Encuesta Europea sobre las Condiciones de Trabajo (EWCS, por sus siglas en inglés), coordinada por la Fundación Europea para la Mejora de las Condiciones de Vida y de Trabajo (Eurofound)¹⁶. El trabajo de campo de esta ola se realizó entre los meses de febrero y noviembre de 2024, abarcando entrevistas cara a cara de aproximadamente 45 minutos de duración a individuos de 35 países, incluyendo los 27 Estados miembros de la UE, Noruega, Suiza y diversos países de los Balcanes.

La muestra total utilizada es altamente representativa y comprende aproximadamente 36.644 trabajadores, incluyendo tanto a empleados por cuenta ajena como a trabajadores por cuenta propia o autónomos. Un aspecto fundamental que debe ser considerado en la metodología es la propia arquitectura de la encuesta: la EWCS utiliza un diseño de muestreo probabilístico complejo, multietápico y estratificado. Este diseño asegura que cada individuo entrevistado represente correctamente a la población activa de su país, corrigiendo posibles desviaciones relativas a la edad, género, ocupación, grado de urbanización y sector económico.

3.2. Definición y estadísticos descriptivos de las variables

Las variables seleccionadas de la EWCS 2024 se estructuran en cuatro bloques: variables independientes (exposición tecnológica), variables dependientes (esfuerzo intensivo y salud), variables de control (factores sociodemográficos y laborales) y variables moderadoras (percepciones sobre la calidad del empleo). La Tabla 1 presenta la descripción, el número de observaciones válidas, las medias ponderadas y la escala de medición de cada variable utilizada en el análisis. En el caso de las variables categóricas con múltiples niveles (edad, país, sector, ocupación y tamaño del centro de trabajo), no se reporta un estadístico único en la columna de medias, dado que su distribución se detalla en las Tablas 2 a 6; para el sexo se indica el porcentaje de mujeres.

Tabla 1. Descripción y estadísticos descriptivos ponderados de las variables del estudio (EWCS 2024, N=36.644)

Variable	Descripción	Bloque	N válidos	Media/ (%)	Es cal a	VIF
----------	-------------	--------	-----------	------------	----------	-----

¹⁶ Eurofound (2026a). *European Working Conditions Survey, 2024* [conjunto de datos]. UK Data Service. SN: 9511. <https://doi.org/10.5255/UKDA-SN-9511-1>

tech_genAI	Uso de IA generativa (ChatGPT, DALL-E...)	Independiente	36.451	12.0% (n=4.187)	0/1	1.13
tech_coopplatforms	Uso de plataformas de cooperación digital	Independiente	36.469	36.0% (n=12.299)	0/1	1.19
tech_cobots	Uso de robots colaborativos (cobots)	Independiente	36.428	3.4% (n=1.133)	0/1	1.02
highspeed_r	Ritmo elevado de trabajo (invertida)	Dep. Esfuerzo	36.510	3.67	1-7	—
tightdead_r	Plazos ajustados de trabajo (invertida)	Dep. Esfuerzo	36.421	3.64	1-7	—
stress_r	Estrés laboral (invertida)	Dep. Esfuerzo	36.454	2.78	1-5	—
health_anxiety_r	Ansiedad en los últimos 12 meses	Dep. Salud	36.248	20.6% (n=8.588)	0/1	—
sleeping_r	Dificultades para dormir (invertida)	Dep. Salud	36.495	1.81	1-4	—
selfhealth_r	Salud autoevaluada (1=muy buena, 5=muy mala)	Dep. Salud	36.603	1.93	1-5	—
health_headaches_r	Dolores de cabeza (últimos 12 meses)	Dep. Salud	36.299	47.1% (n=16.910)	0/1	—
health_musc_upper_r	Dolor muscular superior (últimos 12 meses)	Dep. Salud	36.529	52.2% (n=18.822)	0/1	—
health_musc_lower_r	Dolor muscular inferior (últimos 12 meses)	Dep. Salud	36.429	37.7% (n=14.712)	0/1	—
health_backache_r	Dolor de espalda (últimos 12 meses)	Dep. Salud	36.511	52.0% (n=18.597)	0/1	—
sex2	Género (Male/Female)	Control	36.603	46.4%	Factor	1.12
age_bands	Tramo de edad (6 categorías)	Control	36.644	—	Factor	1.05
country	País (35 países)	Control	36.644	—	Factor	—
seniority	Antigüedad en la empresa (años)	Control	36.039	10.2	Cont.	1.23
occupation	Grupo ocupacional ISCO	Control	36.644	—	Factor	1.10
sector	Sector económico NACE	Control	36.644	—	Factor	1.06
wp_size	Tamaño del centro de trabajo	Control	35.861	—	Factor	1.02
expected_hours_week	Horas semanales esperadas	Control	26.064	36.0	Cont.	1.06
goodjob_workload_r	Importancia de carga manejable (invertida)	Moderadora	36.498	3.57	1-4	—
goodjob_aut_r	Importancia de autonomía (invertida)	Moderadora	36.354	3.35	1-4	—

goodjob_safe_r	Importancia de entorno seguro (invertida)	Moderadora	36.468	3.68	1-4	—
goodjob_secureempl_r	Importancia de seguridad laboral (invertida)	Moderadora	36.321	3.55	1-4	—
goodjob_wlb_r	Importancia de conciliación (invertida)	Moderadora	36.496	3.59	1-4	—
fair_treatment_r	Percepción de trato justo (invertida)	Moderadora	30.348	4.26	1-5	—

La última columna de la Tabla 1 recoge el GVIF ajustado ($GVIF^{1/(2 \cdot Df)}$) para los predictores de los modelos principales (Tabla 7). Este estadístico es el equivalente generalizado del VIF, apropiado para variables categóricas con múltiples niveles. El umbral estándar de referencia es $VIF < 10$, y en la práctica se considera aceptable por debajo de 5. Como puede observarse, ninguna variable se aproxima a dicho umbral: el valor más elevado corresponde a la antigüedad en el puesto (1.23), seguido de las plataformas de cooperación (1.19), de modo que todos los predictores se sitúan muy por debajo del nivel de preocupación. Esto confirma la ausencia de problemas de multicolinealidad. El diagnóstico se calcula únicamente sobre los predictores de los modelos principales: el efecto fijo de país (35 categorías) se excluye, ya que su elevada dimensionalidad genera una deficiencia de rango que impide obtener un VIF estable, sin que ello afecte a la estimación de los modelos; y las variables moderadoras, que solo intervienen en los modelos de interacción (Tablas 10 y 11), tampoco se incluyen en este cálculo, por lo que figuran sin valor de VIF. No se reporta el VIF de las variables dependientes al no constituir predictores. Para las variables binarias se indica entre paréntesis el número de usuarios (n; observaciones sin ponderar), mientras que el porcentaje es ponderado, de modo que ambas cifras no coinciden de forma exacta.

Conviene precisar el estatus de las variables de control. Se trata de un conjunto de factores mayoritariamente sociodemográficos y estructurales (el género, el tramo de edad, el país, la antigüedad en la empresa, el grupo ocupacional, el sector de actividad, el tamaño del centro de trabajo y las horas semanales esperadas) que se incorporan a los modelos para aislar la asociación entre la exposición a la IA y los resultados de esfuerzo y salud de la influencia de estas características. Varias de ellas podrían constituir hipótesis de investigación por derecho propio, pues la literatura documenta efectos relevantes de la edad, el género o el contexto sectorial e institucional sobre las condiciones de trabajo. No obstante, dada la extensión y el foco de este trabajo, no se les ha dedicado la misma atención analítica que a las variables centrales y se mantienen como controles, cuyo papel propio se examina de forma acotada en el apartado 4.8.

3.3. Estrategia empírica y análisis computacional en R

El tratamiento de una base de datos proveniente de un muestreo complejo y multinacional requiere un entorno estadístico robusto. Por este motivo, el análisis completo; importación, limpieza de variables y modelización econométrica, se ejecuta mediante código desarrollado en R, empleando intensivamente el paquete survey¹⁷.

Para realizar inferencias estadísticas correctas y representativas a nivel poblacional, no se pueden emplear regresiones lineales de Mínimos Cuadrados Ordinarios (MCO) de manera estándar, dado que estas asumen que la muestra es aleatoria simple. Ignorar los estratos, las unidades primarias de muestreo (PSUs) y las ponderaciones de la EWCS 2024 llevaría inevitablemente a una subestimación de los errores estándar y a falsos descubrimientos de significatividad estadística.

El protocolo analítico sigue cuatro pasos. Primero, se define el diseño muestral mediante `svydesign()`, declarando explícitamente los pesos de calibración (`calweight`), los estratos (`stratumid`) y las PSUs (`samplingpointid`). Segundo, se realiza un preprocesamiento exhaustivo que convierte los valores perdidos a NA y recodifica las escalas para que valores mayores indiquen mayor intensidad del fenómeno. Tercero, se estiman modelos de regresión ponderada mediante `svyglm()` con familia gaussiana. Para las variables dependientes binarias de salud, esta especificación equivale a un modelo de probabilidad lineal, por el que se opta porque sus coeficientes se interpretan directamente como efectos marginales sobre la probabilidad, en puntos porcentuales, y resultan comparables con los de las variables continuas de esfuerzo, mientras que la inferencia se apoya en los errores estándar derivados del diseño muestral, válidos pese a la heterocedasticidad propia de este modelo. Se trata, además, de una especificación habitual en econometría laboral aplicada que evita la inestabilidad que la regresión logística puede presentar al combinar predictores poco frecuentes, como los cobots (3,4%), con un elevado número de efectos fijos. Los p-valores se calculan mediante la distribución normal estándar, apropiada para muestras de gran tamaño ($n=36.644$). Cuarto, se incorporan términos de interacción multiplicativos para testear los efectos moderadores de género (H2) y de los intereses laborales (H3).

La forma funcional genérica del modelo es:

$$Y_i = \beta_0 + \beta_1 \cdot \text{ExposicionIA}_i + \beta_2 \cdot \text{Controles}_i + \beta_3 \cdot \text{Moderadoras}_i + \beta_4 \cdot (\text{ExposicionIA}_i \times \text{Moderadoras}_i) + \varepsilon_i$$

¹⁷ Lumley, T. (2010). *Complex surveys: A guide to analysis using R*. Wiley, Hoboken (Nueva Jersey).

Donde Y_i representa secuencialmente cada variable dependiente de esfuerzo y salud; $Exposición_{IA}$ captura la exposición a la IA generativa, las plataformas de cooperación digital y los cobots; $Controles$ integra las variables sociodemográficas y laborales; y el término de interacción permite testear la heterogeneidad del efecto según género y intereses laborales.

4. ANÁLISIS DE RESULTADOS


En esta sección se presentan los resultados empíricos del análisis econométrico. El análisis se estructura en torno a las tres preguntas de investigación y las tres hipótesis del estudio, siguiendo el orden lógico establecido en el marco teórico: primero se describe el nivel de adopción de la IA en Europa (PdI 1), después se analiza su efecto sobre el esfuerzo intensivo y la salud de los trabajadores (PdI 2, H1), y finalmente se examina si ese efecto difiere por género (H2) y según los intereses laborales del trabajador (H3) (PdI 3).

4.1. Estadísticos descriptivos: adopción de la IA en Europa (PdI 1)

El análisis descriptivo, basado en medias ponderadas calculadas con el diseño muestral de la EWCS 2024, muestra que el 12,0% de los trabajadores europeos utiliza herramientas de IA generativa en su actividad laboral, porcentaje que coincide con las estimaciones publicadas por Eurofound en los primeros informes sobre la edición 2024 de la encuesta. Las plataformas de cooperación digital tienen una penetración mucho mayor, alcanzando el 36,0% de los trabajadores, mientras que los robots colaborativos presentan la tasa de adopción más baja, con tan solo un 3,4%.

El análisis por género, recogido en la Figura 1, revela patrones de adopción diferenciados. Los hombres muestran una mayor propensión al uso de IA generativa (13,9% frente al 9,8% de las mujeres) y de cobots (4,0% frente al 2,7%). Por el contrario, las mujeres presentan una adopción ligeramente superior de plataformas de cooperación (36,8% frente al 35,3%), lo que puede asociarse a su mayor presencia en empleos del sector servicios con alto componente de trabajo colaborativo.

Figura 1. Tasa de adopción de tecnologías de IA en el trabajo (IA generativa, plataformas de cooperación digital y cobots) por género. EWCS 2024.



El análisis por grupo ocupacional muestra que el uso de IA generativa está muy concentrado en los grupos de mayor cualificación: directivos (23,7%) y profesionales (27,7%), frente al 1,4% de los trabajadores elementales. En el caso de los cobots, destaca el grupo de operadores de máquinas e instalaciones (10,1%), lo que es coherente con la dimensión de automatización física que caracteriza a este tipo de tecnología. El análisis sectorial revela que el sector de información y comunicación (NACE J) es el que presenta la adopción más elevada de IA generativa, con un 47,5%, muy por encima de la media europea, seguido del sector financiero e inmobiliario (KL, 27,1%) y la educación (P, 18,7%). En el extremo opuesto, la agricultura (A, 1,3%) y la hostelería (I, 4,0%) presentan las tasas más bajas.

El análisis por país revela una notable heterogeneidad en los niveles de adopción tecnológica dentro de Europa. En relación con la IA generativa, los países con mayor adopción son Luxemburgo (25,0%), Suiza (24,4%), Noruega (21,6%) y Suecia (20,8%), todos ellos economías avanzadas del norte y centro de Europa con altos niveles de digitalización y cualificación de su fuerza laboral. En el extremo opuesto, Bosnia-Herzegovina (2,8%), Serbia (3,5%), Rumanía (3,8%) y Portugal (3,8%) presentan las tasas más bajas, reflejando la persistente brecha digital entre el norte y el sur y el este de Europa. España se sitúa en la media europea con un 11,0%. La Tabla 2 recoge los resultados completos ordenados por tasa de adopción de IA generativa.

Tabla 2. Tasa de adopción de IA generativa, plataformas de cooperación y cobots por país (selección). EWCS 2024.

País	IA generativa (%)	Plat. Cooperación (%)	Cobots (%)
Luxemburgo	25.0	49.1	5.9
Suiza	24.4	53.3	4.3

Noruega	21.6	69.5	3.3
Suecia	20.8	71.9	2.7
Bélgica	19.7	46.6	3.7
Dinamarca	19.5	53.5	7.1
Países Bajos	19.5	54.6	3.0
Kosovo	18.9	26.5	6.0
Austria	18.3	39.7	6.5
Finlandia	17.9	62.9	6.0
España	11.0	37.9	4.5
...	...	...	...
Macedonia del Norte	4.4	16.6	3.2
Portugal	3.8	26.7	3.3
Rumanía	3.8	10.3	2.7
Serbia	3.5	29.9	1.2
Bosnia-Herzegovina	2.8	15.0	2.9

Nota: Se muestran los 10 países con mayor adopción de IA generativa, España y los 5 con menor adopción. Tabla completa disponible en el archivo desc_adopcion_pais.csv.

El tamaño del centro de trabajo es uno de los factores que más claramente se asocia con la adopción tecnológica. Como muestra la Tabla 3, existe una relación positiva y casi lineal entre el tamaño de la empresa y el uso de las tres tecnologías analizadas. Las empresas de 500 o más empleados presentan una tasa de adopción de IA generativa del 24,2%, más del cuádruple que las empresas de 2 a 4 empleados (6,0%). El mismo patrón se observa para las plataformas de cooperación (55,1% frente a 23,2%) y para los cobots (7,7% frente a 1,5%). Este resultado es coherente con la literatura sobre difusión tecnológica: las grandes organizaciones disponen de más recursos para invertir en nuevas tecnologías, cuentan con equipos técnicos especializados para su implementación y tienen mayor capacidad para absorber los costes de adaptación. Es destacable que los trabajadores autónomos o solo trabajadores presenten una tasa de adopción de IA generativa (11,0%) superior a la de las microempresas de 2-4 empleados, lo que podría reflejar el uso individual de herramientas gratuitas de IA generativa como apoyo a la actividad profesional independiente.

Tabla 3. Tasa de adopción de IA generativa, plataformas de cooperación y cobots por tamaño del centro de trabajo. EWCS 2024.

Tamaño del centro de trabajo	IA generativa (%)	Plat. Cooperación (%)	Cobots (%)
Solo trabajador/a	11.0	23.9	1.2
2-4 empleados	6.0	23.2	1.5
5-9 empleados	8.0	29.3	2.6
10-49 empleados	10.2	34.6	3.2
50-99 empleados	12.7	42.5	3.4

100-249 empleados	15.3	45.4	4.3
250-499 empleados	20.0	53.3	7.4
500 o más empleados	24.2	55.1	7.7

Nota: Porcentajes ponderados calculados mediante svyby() con el diseño muestral complejo de la EWCS 2024.

El análisis por tramo de edad, recogido en la Tabla 4, muestra un patrón de adopción que alcanza su máximo en la franja de 25 a 34 años (16,6% en IA generativa y 44,0% en plataformas de cooperación) y desciende de forma progresiva con la edad: 13,7% entre los 35 y 44 años, 11,2% entre los 45 y 54 años, y mínimos en los tramos de mayor edad (8,6% entre los 55 y 64 años y 4,6% entre los 65 y 74). Los trabajadores más jóvenes (16-24 años) presentan una adopción intermedia (9,2%), algo por debajo de los grupos de mediana edad, lo que puede relacionarse con su mayor concentración en empleos de entrada y de menor cualificación. Este perfil descendente con la edad se observa de forma consistente en las tres tecnologías, lo que apunta a una brecha generacional en el acceso a las herramientas digitales en el trabajo.

Tabla 4. Tasa de adopción de IA generativa, plataformas de cooperación y cobots por tramo de edad. EWCS 2024.

Tramo de edad	IA generativa (%)	Plat. Cooperación (%)	Cobots (%)	N
16-24 años	9.2	31.6	2.7	2.649
25-34 años	16.6	44.0	4.2	6.616
35-44 años	13.7	39.2	4.3	8.531
45-54 años	11.2	35.4	3.3	8.760
55-64 años	8.6	29.7	2.2	7.914
65-74 años	4.6	17.0	1.6	2.174

Tabla 5. Tasa de adopción de IA generativa, plataformas de cooperación y cobots por sector de actividad (NACE). EWCS 2024.

Sector de actividad	IA generativa (%)	Plat. Cooperación (%)	Cobots (%)
Información y comunicaciones (J)	47.5	77.1	3.5
Actividades financieras e inmobiliarias (K-L)	27.1	60.1	3.5
Educación (P)	18.7	47.3	1.2
Actividades profesionales y administrativas (M-N)	18.7	44.9	1.9
Industria y energía (B-E)	10.9	33.2	9.8
Administración pública (O)	9.7	49.7	1.4
Transporte y almacenamiento (H)	7.8	27.1	2.6
Comercio (G)	7.6	30.1	2.4
Otros servicios (R-U)	7.3	24.4	0.9

Actividades sanitarias y sociales (Q)	7.1	37.0	2.2
Construcción (F)	5.9	21.9	2.0
Hostelería (I)	4.0	13.7	3.1
Agricultura, ganadería y pesca (A)	1.3	9.6	1.6

Tabla 6. Tasa de adopción de IA generativa, plataformas de cooperación y cobots por ocupación (ISCO). EWCS 2024.

Ocupación	IA generativa (%)	Plat. Cooperación (%)	Cobots (%)
Profesionales científicos e intelectuales (ISCO 2)	27.7	60.2	2.9
Directivos y gerentes (ISCO 1)	23.7	53.7	5.0
Técnicos y profesionales de apoyo (ISCO 3)	13.6	49.9	2.7
Personal de apoyo administrativo (ISCO 4)	10.6	49.6	1.4
Trabajadores de servicios y ventas (ISCO 5)	2.6	18.9	1.8
Trab. cualificados: agricultura, artesanía y oficios (ISCO 6–7)	2.6	13.2	4.5
Operadores de instalaciones y máquinas (ISCO 8)	2.4	10.4	10.1
Ocupaciones elementales (ISCO 9)	1.4	7.3	3.3

Nota: ^a Valor calculado sobre celda con N reducido, interpretar con cautela. Porcentajes ponderados con diseño muestral EWCS 2024.

4.2. Análisis de correlaciones de Spearman

Previo a la estimación de los modelos de regresión, se calcularon las correlaciones de Spearman entre todas las variables del análisis. La Figura 2 presenta la matriz de correlación completa y la Figura 3 muestra de forma simplificada las correlaciones entre las tres variables independientes y todos los resultados de esfuerzo y salud.

Figura 2. Correlaciones de Spearman entre las variables de exposición a la IA, de esfuerzo intensivo y de salud. EWCS 2024.





Figura 3. Correlaciones de Spearman entre las variables de exposición a la IA y los indicadores de esfuerzo y salud. EWCS 2024.



Los resultados muestran que tanto la IA generativa como las plataformas de cooperación presentan correlaciones positivas, aunque débiles, con el esfuerzo intensivo, especialmente con el estrés y los plazos ajustados. Ambas tecnologías muestran además correlaciones ligeramente negativas con la salud general deteriorada, lo que indica que sus usuarios tienden a reportar una salud autopercebida algo mejor. Los cobots, por su parte, presentan correlaciones prácticamente nulas con todos los indicadores, coherente con su baja prevalencia en la muestra. En conjunto, estas correlaciones bivariadas son débiles a moderadas, lo que indica que los efectos observados en los modelos de regresión no se derivan de correlaciones falsas, sino de relaciones controladas por múltiples factores estructurales. Cabe señalar, además, que las correlaciones de Spearman se calculan sobre la muestra sin ponderar como análisis exploratorio previo; las estimaciones ponderadas se presentan en los modelos svyglm de las secciones siguientes.

4.3. El modelo de regresión completo

Antes de contrastar las hipótesis, conviene presentar el modelo de regresión que constituye la especificación de referencia de todo el análisis. Se trata de modelos lineales ponderados (svyglm) estimados con el diseño muestral complejo de la EWCS 2024 sobre los tres resultados centrales (estrés, ansiedad y salud general autoevaluada), en los que se introducen de forma simultánea las tres variables de exposición a la IA y el bloque completo de variables de control. De esta manera, los efectos de las tecnologías que se discuten en los apartados de contraste de hipótesis están ya ajustados por el resto de factores estructurales, mientras que el papel propio de las variables de control se examina de forma separada en el apartado 4.8.

Los resultados completos de los tres modelos de regresión principales se presentan en la Tabla 7, que incluye todos los coeficientes estimados para las variables tecnológicas, el género, la edad, el país, el sector, la ocupación y el tamaño del centro de trabajo. Por razones de parsimonia, en los grupos de país, sector, ocupación y tamaño de empresa se muestran únicamente los coeficientes estadísticamente significativos ($p < 0.05$), indicando con '—' las categorías que no alcanzan dicho umbral. La categoría de referencia para el país es Austria; para el sector, la Agricultura; para la ocupación, los Directivos (ISCO 1); para el género, los hombres; y para el tamaño de empresa, los trabajadores autónomos o sin empleados.

Tabla 7. Modelos de regresión completos para los principales resultados. Efectos de variables tecnológicas y de control. EWCS 2024.

Variable	Estrés	Ansiedad	Salud general
VARIABLES TECNOLÓGICAS (H1)			
IA generativa (tech_genAI)	-0.039 (0.051)	0.022 (0.020)	-0.001 (0.037)
Plat. cooperación (tech_coopplatforms)	0.186*** (0.037)	0.033* (0.014)	-0.032 (0.029)
Cobots (tech_cobots)	0.145 (0.093)	0.048 (0.032)	0.079 (0.054)
GÉNERO (ref: Hombre)			
Mujer	0.169*** (0.031)	0.102*** (0.013)	0.068** (0.023)
GRUPO DE EDAD (ref: <25 años)			
25-34 años	0.063 (0.075)	0.020 (0.023)	0.126** (0.048)
35-44 años	0.080 (0.072)	0.008 (0.023)	0.273*** (0.054)
45-54 años	0.092 (0.078)	0.007 (0.024)	0.454*** (0.056)
55-64 años	-0.121 (0.083)	-0.004 (0.025)	0.575*** (0.061)
65-74 años	-0.363*** (0.102)	-0.062† (0.036)	0.497*** (0.083)
PAÍS (ref: Austria), solo efectos significativos			
Bélgica	-0.336*** (0.068)	0.272*** (0.021)	0.289*** (0.045)
Bulgaria	-1.011*** (0.095)	0.202*** (0.034)	—
Croacia	-0.579*** (0.092)	0.100*** (0.025)	—
Chipre	-0.460*** (0.100)	0.473*** (0.034)	-0.174** (0.053)
Chequia	-0.381*** (0.080)	0.121*** (0.027)	0.282*** (0.063)
Dinamarca	-0.774*** (0.077)	—	0.124* (0.054)
Estonia	-0.693*** (0.083)	0.296*** (0.029)	0.445*** (0.053)
Finlandia	-0.612*** (0.072)	0.203*** (0.025)	0.238*** (0.052)
Francia	-0.646*** (0.093)	0.261*** (0.030)	0.131* (0.052)
Alemania	—	0.050* (0.022)	0.344*** (0.054)
Grecia	—	0.644*** (0.032)	-0.226*** (0.057)
Hungría	-0.585*** (0.097)	—	0.122* (0.058)
Irlanda	-0.434*** (0.094)	0.122*** (0.026)	-0.207*** (0.054)
Italia	-0.604*** (0.099)	0.099*** (0.028)	0.393*** (0.095)

Letonia	-0.595*** (0.076)	0.303*** (0.028)	0.538*** (0.050)
Lituania	-0.739*** (0.078)	0.294*** (0.030)	0.367*** (0.054)
Luxemburgo	-0.243* (0.101)	0.252*** (0.039)	0.273*** (0.064)
Malta	-0.524*** (0.103)	0.235*** (0.026)	—
Países Bajos	-0.774*** (0.078)	0.158*** (0.028)	0.249*** (0.052)
Noruega	-0.229** (0.074)	0.097*** (0.026)	0.381*** (0.057)
Polonia	-0.730*** (0.093)	—	—
Portugal	-0.567*** (0.111)	0.245*** (0.033)	0.114* (0.056)
Rumanía	-0.780*** (0.099)	—	0.181** (0.065)
Eslovaquia	-0.459*** (0.092)	—	0.181** (0.058)
Eslovenia	-0.643*** (0.082)	0.087*** (0.022)	0.116* (0.053)
España	-0.371*** (0.074)	0.196*** (0.028)	0.136* (0.061)
Suecia	-0.375*** (0.074)	0.187*** (0.028)	0.273*** (0.056)
Suiza	-0.360*** (0.074)	0.115*** (0.025)	—
Albania	-0.346*** (0.086)	—	—
Bosnia-Herzegovina	-0.603*** (0.087)	0.089** (0.032)	0.257** (0.086)
Macedonia del Norte	-0.750*** (0.101)	—	-0.127* (0.056)
Kosovo	-0.478*** (0.120)	—	—
Montenegro	-0.542*** (0.097)	0.136*** (0.029)	0.284*** (0.071)
Serbia	-0.521*** (0.088)	0.260*** (0.034)	0.182** (0.064)
SECTOR (ref: Agricultura), solo efectos significativos			
Transporte (H)	0.326* (0.136)	—	—
Hostelería (I)	0.486*** (0.140)	—	—
Sanidad y serv. sociales (Q)	0.336* (0.136)	—	—
OCUPACIÓN (ref: Directivos), solo efectos significativos			
Empleados apoyo (ISCO 4)	-0.277*** (0.082)	—	—
Trab. cualificados (ISCO 6–7)	—	—	0.189*** (0.057)
Operadores máquinas (ISCO 8)	-0.177* (0.087)	—	0.217*** (0.060)
Trabajadores elementales (ISCO 9)	-0.203* (0.103)	—	0.226*** (0.062)
TAMAÑO EMPRESA (ref: Solo trabajador/a), solo efectos significativos			
2-4 empleados	—	-0.113* (0.049)	—
10-49 empleados	0.359** (0.122)	-0.103* (0.045)	—
50-99 empleados	0.403** (0.132)	—	—
100-249 empleados	0.412** (0.129)	—	—
500 o más empleados	0.388** (0.134)	—	—
OTROS CONTROLES			
Antigüedad (años)	0.009*** (0.002)	0.000 (0.001)	0.001 (0.002)
Horas semanales esperadas	0.014*** (0.003)	0.001 (0.001)	0.000 (0.001)

Nota: Coeficientes con errores estándar entre paréntesis. Solo se muestran los efectos de país, sector, ocupación y tamaño de empresa estadísticamente significativos ($p < 0.05$). '—' indica efecto no significativo. Todas las variables

dependientes están recodificadas de modo que valores mayores indican mayor intensidad del fenómeno (más estrés, más ansiedad o peor salud). † $p<0.10$; * $p<0.05$; ** $p<0.01$; *** $p<0.001$. Las horas semanales esperadas y la antigüedad se controlan en todos los modelos; algunos coeficientes por unidad inferiores a 0,001 en valor absoluto aparecen como 0,000, lo que no indica datos ausentes.

4.4. Efecto de la IA sobre el esfuerzo intensivo (H1a)

Los resultados de los modelos de regresión lineal ponderada para las tres variables de esfuerzo intensivo se presentan en la Tabla 8. En todos los casos el modelo incluye el conjunto completo de variables de control.

Tabla 8. Efecto de la exposición tecnológica sobre el esfuerzo intensivo. Modelos svyglm, EWCS 2024.

Variable independiente	Ritmo elevado	Plazos ajustados	Estrés
IA generativa (tech_genAI)	0.118 (0.090)	0.299** (0.093)	-0.039 (0.051)
Plat. cooperación (tech_coopplatforms)	0.172* (0.073)	0.438*** (0.074)	0.186*** (0.037)
Cobots (tech_cobots)	0.361* (0.156)	0.068 (0.156)	0.145 (0.093)
Variables de control	Incluidas	Incluidas	Incluidas
N	24.934	24.880	24.932

*Nota: Coeficientes con errores estándar entre paréntesis. † $p<0.10$; * $p<0.05$; ** $p<0.01$; *** $p<0.001$. Variables dependientes invertidas: valores mayores indican mayor esfuerzo/presión.*

Los resultados muestran un patrón claramente diferenciado según el tipo de tecnología. Las plataformas de cooperación son la tecnología que más se asocia con un esfuerzo intensivo: su uso se relaciona con un ritmo de trabajo más elevado ($\beta=0.172$, $p<0.05$), unos plazos más ajustados ($\beta=0.438$, $p<0.001$) y un mayor nivel de estrés ($\beta=0.186$, $p<0.001$). Las tres dimensiones del esfuerzo apuntan en la misma dirección, lo que respalda H1a y es coherente con interpretar estas plataformas como una demanda laboral en el sentido del marco JD-R, y no como un recurso. La IA generativa, en cambio, solo se relaciona con unos plazos más ajustados ($\beta=0.299$, $p<0.01$), sin asociación significativa con el ritmo ($\beta=0.118$, n.s.) ni con el estrés ($\beta=-0.039$, n.s.): sus usuarios reportan una mayor presión temporal, pero no un mayor esfuerzo o tensión general. Los cobots solo se asocian con un ritmo de trabajo más elevado ($\beta=0.361$, $p<0.05$), sin relación significativa con el estrés ni con los plazos. En conjunto, el esfuerzo intensivo se relaciona sobre todo con las plataformas de cooperación, de forma más puntual con los cobots (únicamente el ritmo) y solo en la dimensión de plazos con la IA generativa.

4.5. Efecto de la IA sobre la salud y el bienestar (H1b)

La Tabla 9 recoge los coeficientes para las siete variables de salud y bienestar.


Tabla 9. Efecto de la exposición tecnológica sobre la salud y el bienestar. Modelos svyglm, EWCS 2024.

Variable independiente	Ansiedad	Sueño	Salud gral.	D. cabeza	Musc. sup.	Musc. inf.	Espalda
IA generativa	0.022 (0.020)	-0.060 (0.045)	-0.001 (0.037)	0.008 (0.024)	0.013 (0.027)	0.021 (0.024)	0.029 (0.026)
Plat. coop.	0.033* (0.014)	0.079** (0.029)	-0.032 (0.029)	0.138*** (0.019)	0.043* (0.022)	-0.020 (0.017)	0.015 (0.020)
Cobots	0.048 (0.032)	0.091 (0.075)	0.079 (0.054)	-0.084* (0.036)	0.015 (0.038)	0.014 (0.034)	-0.002 (0.032)
Variables de control	Incl.	Incl.	Incl.	Incl.	Incl.	Incl.	Incl.
N	24.799	24.922	24.982	24.812	24.932	24.874	24.919

*Nota: Coeficientes con errores estándar entre paréntesis. Las variables de salud binarias están recodificadas como 1=presencia del problema de salud; la salud general autoevaluada y las dificultades de sueño son variables ordinales en las que un valor mayor indica, respectivamente, peor salud autopercebida y más dificultades para dormir. † $p<0.10$; * $p<0.05$; ** $p<0.01$; *** $p<0.001$.*

Las plataformas de cooperación son la tecnología con mayor asociación con problemas de salud y bienestar. Su uso se relaciona con más ansiedad ($\beta=0.033$, $p<0.05$), más dificultades de sueño ($\beta=0.079$, $p<0.01$), más dolores de cabeza ($\beta=0.138$, $p<0.001$) y más dolor muscular en la zona superior del cuerpo ($\beta=0.043$, $p<0.05$). Este patrón es coherente con su papel como demanda laboral observado sobre el esfuerzo: la intensificación se traslada también al plano de la salud. La IA generativa no muestra asociación significativa con ninguna de las siete variables de salud, lo que matiza H1b: su uso no se relaciona ni con un deterioro ni con una mejora de la salud autopercebida o física. Los cobots presentan un patrón débil: su única asociación significativa es con menos dolores de cabeza ($\beta=-0.084$, $p<0.05$), sin relación con la salud general, el sueño, la ansiedad ni el resto de indicadores. En conjunto, el vínculo entre exposición tecnológica y salud se concentra en las plataformas de cooperación, y no en los cobots como cabría esperar de una tecnología de carácter físico. La Figura 4 representa de forma conjunta estos efectos de la exposición tecnológica sobre el esfuerzo y la salud, junto con sus intervalos de confianza al 95%.

Figura 4. Efecto de la exposición a tecnologías de IA sobre el esfuerzo y la salud (coeficientes de regresión con IC 95%). EWCS 2024.



4.6. Efecto asimétrico por género (H2)

La Tabla 10 recoge los coeficientes de interacción tecnología × género.

Tabla 10. Efecto moderador del género. Términos de interacción. EWCS 2024.

Variable independiente	Estrés	Ansiedad	Salud general
IA generativa × Mujer	0.172† (0.091)	-0.002 (0.034)	-0.016 (0.060)
Plat. coop. × Mujer	-0.102 (0.065)	0.025 (0.024)	0.042 (0.044)
Cobots × Mujer	0.150 (0.188)	0.017 (0.061)	-0.043 (0.111)
Variables de control	Incluidas	Incluidas	Incluidas
N	24.932	24.799	24.982

*Nota: Términos de interacción. Un coeficiente positivo indica que el efecto es mayor (más negativo) para las mujeres. † $p < 0.10$; * $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$.*

H2 no queda apoyada. Ninguno de los términos de interacción tecnología × género alcanza la significación estadística convencional en estrés, ansiedad o salud general. El único coeficiente que se aproxima es la interacción entre la IA generativa y el género en el estrés ($\beta=0.172$, $p<0.10$), que apunta a una posible, aunque débil, tendencia de las mujeres usuarias de IA generativa a reportar algo más de estrés, sin llegar a confirmarse. Las interacciones de las plataformas de cooperación y de los cobots con el género no son significativas para ninguno de los tres resultados. En la muestra analizada, por tanto, no se observa el efecto asimétrico por género que predecía H2: la asociación entre exposición tecnológica y esfuerzo o salud no difiere de forma significativa entre hombres y mujeres.

4.7. Efecto moderador de los intereses laborales (H3)

La Tabla 11 recoge los términos de interacción para los cuatro modelos de moderación.

Tabla 11. Efecto moderador de los intereses laborales. Términos de interacción. EWCS 2024.

Variable independiente	Est.×Workload	Est.×Autonomía	Ans.×Trato	Ans.×Seguridad
IA generativa × Mod.	-0.020 (0.076)	-0.072 (0.081)	-0.019 (0.022)	-0.028 (0.024)
Plat. coop. × Mod.	0.147** (0.056)	0.033 (0.046)	-0.001 (0.015)	0.022 (0.017)
Cobots × Mod.	-0.275† (0.145)	-0.025 (0.158)	-0.017 (0.031)	-0.031 (0.055)
Variables de control	Incluidos	Incluidos	Incluidos	Incluidos
N	24.871	24.773	24.635	24.693

*Nota: Términos de interacción. Las moderadoras están invertidas: valores mayores indican mayor importancia del atributo laboral. † $p < 0.10$; * $p < 0.05$; ** $p < 0.01$; *** $p < 0.001$.*

H3 no queda apoyada en su formulación principal. La predicción central derivada del modelo ERI, que valorar la seguridad laboral amplifica el efecto de la IA sobre la ansiedad, no se confirma: la interacción entre la IA generativa y la importancia concedida a la seguridad laboral no es significativa ($\beta = -0.028$, n.s.), como tampoco la de los cobots ($\beta = -0.031$, n.s.) ni el resto de interacciones con la seguridad. La única moderación significativa se observa entre las plataformas de cooperación y la importancia concedida a una carga de trabajo manejable sobre el estrés ($\beta = 0.147$, $p < 0.01$): la asociación entre el uso de plataformas y el estrés es más intensa entre quienes más valoran una carga de trabajo manejable, lo que resulta coherente con el papel de estas plataformas como demanda laboral. De forma marginal, los cobots muestran la interacción opuesta con esa misma moderadora ($\beta = -0.275$, $p < 0.10$). Ninguna de las restantes interacciones con la autonomía, el trato justo o la seguridad alcanza significación. En conjunto, los intereses laborales no moderan la relación entre IA y bienestar en la forma prevista por H3; la única excepción es la sensibilidad a la carga de trabajo en el caso de las plataformas.

4.8. Las variables de control

Los modelos completos (Tabla 7) muestran también patrones contextuales de interés. En el estrés, Austria, la categoría de referencia, se sitúa entre los países con mayor nivel: la mayoría de los países presentan coeficientes negativos y significativos, es decir, menos estrés que Austria. Las mujeres reportan más estrés que los hombres ($\beta = 0.169$, $p < 0.001$), la antigüedad se asocia con un ligero aumento ($\beta = 0.009$, $p < 0.001$) y unas jornadas semanales más largas también se vinculan a más estrés ($\beta = 0.014$, $p < 0.001$). Por tamaño, el estrés crece con la dimensión de la empresa: los trabajadores de centros medianos y grandes reportan más estrés que los autónomos, desde $\beta = 0.359$ en empresas de 10-49 empleados hasta

$\beta=0.412$ en las de 100-249. Entre los sectores, la hostelería ($\beta=0.486$, $p<0.001$), la sanidad ($\beta=0.336$, $p<0.05$) y el transporte ($\beta=0.326$, $p<0.05$) destacan por un mayor estrés frente a la agricultura de referencia.

En la ansiedad, las mujeres vuelven a reportar niveles más altos ($\beta=0.102$, $p<0.001$) y las diferencias entre países son generalizadas, sin un patrón sectorial nítido. Los trabajadores de empresas pequeñas presentan, si acaso, algo menos de ansiedad que los autónomos (2-4 empleados: $\beta=-0.113$, $p<0.05$; 10-49 empleados: $\beta=-0.103$, $p<0.05$).

En la salud general autopercibida, donde un valor mayor indica peor salud, el factor dominante es la edad: la salud empeora de forma prácticamente monótona con los años, desde $\beta=0.126$ en el tramo de 25-34 hasta $\beta=0.575$ en el de 55-64. Las mujeres reportan una salud ligeramente peor ($\beta=0.068$, $p<0.01$). Por ocupación, los trabajadores cualificados ($\beta=0.189$, $p<0.001$), los operadores de maquinaria ($\beta=0.217$, $p<0.001$) y los trabajadores elementales ($\beta=0.226$, $p<0.001$) declaran peor salud que los directivos de referencia, en línea con el gradiente socioeconómico de la salud.

4.9. Síntesis de hipótesis

La Tabla 12 sintetiza el grado de apoyo empírico obtenido para cada una de las tres hipótesis del estudio, integrando los resultados presentados en los apartados anteriores.

Tabla 12. Resumen del contraste de hipótesis.

Hip.	Enunciado resumido	Resultado	Evidencia clave
H1	Exposición tecnológica → mayor esfuerzo y peor salud	Parcialmente apoyada	Plataformas → esfuerzo y salud (β hasta 0.44***); genAI solo plazos**; cobots ritmo*
H2	El impacto negativo es mayor en mujeres	No apoyada	Interacciones × género n.s.; solo genAI×Mujer→estrés†
H3	Intereses laborales moderan el impacto tecnológico	No apoyada	Amplificación ERI no confirmada; solo plataformas×carga→estrés**

5. DISCUSIÓN Y CONCLUSIÓN

El objetivo de este trabajo era analizar de qué manera la exposición a distintas tecnologías de inteligencia artificial influye en las condiciones de trabajo de los empleados europeos, tanto en el esfuerzo intensivo percibido como en la salud, y si los intereses laborales de los

trabajadores modulan esa relación. El análisis descriptivo ofrece una primera respuesta: la adopción de la IA en Europa es todavía moderada y muy desigual. El uso de la IA generativa sigue siendo minoritario, las plataformas de cooperación digital están considerablemente más extendidas y el trabajo con cobots es aún marginal; además, su uso se concentra en las ocupaciones cualificadas, las grandes organizaciones y los países del norte y centro del continente. Sobre este telón de fondo, los modelos de regresión ponderada ofrecen una imagen matizada que se aleja del planteamiento inicial: lejos de un efecto uniforme y negativo, el impacto de la IA depende del tipo de tecnología, de la dimensión analizada y del perfil del trabajador, en línea con el modelo de Demandas y Recursos del Trabajo (JD-R), según el cual una misma característica del entorno laboral puede funcionar como demanda o como recurso.

En lo que respecta a la relación esperada entre la exposición a la IA y el esfuerzo intensivo, los modelos la confirman, pero el protagonismo recae en una tecnología distinta a la prevista. Son las plataformas de cooperación digital, y no la IA generativa, las que más se relacionan con la intensificación del trabajo: su uso se asocia con un mayor ritmo, unos plazos más ajustados y más estrés, las tres dimensiones en la misma dirección. Lejos de operar como un recurso, estas plataformas funcionan como una demanda laboral en el sentido del modelo JD-R, un resultado que conecta con la literatura sobre gestión algorítmica y coordinación digital del trabajo. La IA generativa, en cambio, solo se asocia con unos plazos más ajustados, sin relación significativa con el ritmo ni con el estrés: su uso se vincula a una mayor presión temporal, pero no a una mayor tensión general. Los cobots se relacionan únicamente con un ritmo más elevado, sin asociación significativa con el estrés ni con los plazos. El patrón respalda esa expectativa, aunque solo de forma parcial: el efecto se confirma con claridad para las plataformas de cooperación, de forma más puntual para los cobots (solo en el ritmo) y únicamente en la dimensión de plazos para la IA generativa.

Los resultados sobre la salud refuerzan esta lectura y vuelven a situar a las plataformas de cooperación en el centro. Son ellas las que muestran la asociación más clara con problemas de salud: su uso se relaciona con más ansiedad, más dificultades de sueño, más dolores de cabeza y más dolor muscular en la zona superior del cuerpo. Este patrón es coherente con su papel como demanda observado sobre el esfuerzo: la intensificación se traslada también al plano de la salud, en línea con la cadena «mayor demanda, peor bienestar» del modelo JD-R. La IA generativa no muestra ninguna asociación significativa con la salud, ni en sentido adverso ni protector, lo que matiza tanto la previsión de un deterioro de la salud

asociado a la exposición tecnológica como las visiones que la presentan como un factor de deterioro inmediato del bienestar. Los cobots presentan un patrón débil en el plano de la salud: su única asociación significativa es con menos dolores de cabeza, sin un deterioro claro de la salud general ni del resto de indicadores, lejos del perfil físicamente adverso que cabría esperar de una tecnología de carácter manual. En conjunto, la cadena «mayor esfuerzo, peor salud» que anticipaba el planteamiento inicial encuentra apoyo, pero canalizada a través de las plataformas de cooperación y no del conjunto de las tecnologías; con datos transversales, además, no puede contrastarse como una relación causal.

La previsión de que el efecto adverso de la IA sobre la salud fuera más acusado en las mujeres no recibe apoyo. En el plano descriptivo, los hombres utilizan más la IA generativa y los cobots y las mujeres algo más las plataformas de cooperación; pero en el plano multivariado esa asimetría no se traduce en efectos diferenciados. Ninguno de los términos de interacción tecnología $\times$ género alcanza la significación convencional en estrés, ansiedad o salud: la única señal, débil y no concluyente, es una ligera tendencia de las mujeres usuarias de IA generativa a reportar algo más de estrés. La asociación entre exposición tecnológica y bienestar no difiere, por tanto, de forma significativa entre hombres y mujeres en esta muestra. Este resultado contrasta con la asimetría que anticipaba la teoría del Desequilibrio Esfuerzo-Recompensa y con parte de la literatura sobre la doble carga, y sugiere que, al menos en términos de moderación estadística, el género no condiciona el efecto de estas tecnologías sobre las condiciones de trabajo.

El papel moderador previsto de los intereses laborales tampoco se confirma en su formulación principal. La predicción central derivada del modelo ERI, que valorar la seguridad en el empleo amplifica el efecto de la IA sobre la ansiedad, no se sostiene: la interacción entre la IA generativa (o los cobots) y la importancia concedida a la seguridad laboral no es significativa. La única moderación que emerge se da entre las plataformas de cooperación y la importancia concedida a una carga de trabajo manejable: la asociación entre el uso de plataformas y el estrés es más intensa entre quienes más valoran no estar sobrecargados, un resultado coherente con el papel de estas plataformas como demanda. Los intereses laborales no modulan, pues, el impacto de la IA en la forma prevista; la sensibilidad a la carga de trabajo, y solo en el caso de las plataformas, constituye la única excepción.

Considerados en conjunto, los hallazgos respaldan una interpretación contingente del impacto de la inteligencia artificial sobre la calidad del empleo, aunque con un protagonista

inesperado. Las tecnologías analizadas no afectan por igual a las condiciones de trabajo: el efecto depende del tipo de herramienta y de la dimensión considerada. El resultado más llamativo es que la tecnología más extendida, las plataformas de cooperación digital, es también la que más se asocia con la intensificación del trabajo y con un peor bienestar, mientras que la más mediática, la IA generativa, muestra efectos limitados y circunscritos a la presión por plazos, y los cobots ofrecen un patrón débil y mixto. Una posible explicación de este contraste reside en quién controla la tecnología: la IA generativa suele ser una herramienta que el propio trabajador adopta y maneja para apoyar su tarea, más próxima a un recurso, mientras que las plataformas de cooperación imponen una coordinación y unos ritmos definidos en buena medida por la organización, más próximos a una demanda; una distinción coherente con la lógica del modelo JD-R. Esta lectura permite superar el debate polarizado entre las visiones optimista y crítica señalado por Gong et al.¹⁸ y desplazarlo hacia un enfoque dependiente del tipo concreto de tecnología, y resulta coherente con los indicadores de Eurofound sobre la reintensificación del trabajo¹⁹.

Estos resultados deben interpretarse a la luz de varias limitaciones. En primer lugar, el diseño de la EWCS 2024 es transversal y observacional, por lo que las asociaciones identificadas no permiten establecer relaciones de causalidad. En segundo lugar, todas las variables proceden de autoinformes, expuestos a sesgos de percepción y a diferencias culturales en los estilos de respuesta, especialmente visibles en las marcadas diferencias de salud autopercebida entre países. En tercer lugar, la variable de plataformas de cooperación digital agrupa herramientas heterogéneas, desde la simple colaboración digital hasta la coordinación y asignación algorítmica de tareas, por lo que su interpretación como demanda vinculada a la gestión algorítmica debe tomarse con cautela. En cuarto lugar, la estimación simultánea de un número elevado de modelos y coeficientes aconseja prudencia con los efectos aislados y de menor magnitud, que podrían reflejar hallazgos espurios; los resultados centrales, en cambio, se sostienen sobre patrones coherentes y altamente significativos. En quinto lugar, la baja prevalencia de los cobots (3,4% de la muestra) hace que sus estimaciones sean menos precisas, y la muestra analítica de los modelos (en torno a 25.000 observaciones, frente a las 36.644 de los análisis descriptivos) se reduce por la eliminación

¹⁸ Gong, Q., Fan, D. y Bartram, T. (2025). Integrating artificial intelligence and human resource management: A review and future research agenda. *The International Journal of Human Resource Management*, 36(1), 103–141. <https://doi.org/10.1080/09585192.2024.2440065>

¹⁹ Eurofound (2026b). *European Working Conditions Survey 2024: Overview report*. Eurofound, Dublín. <https://www.eurofound.europa.eu/en/publications/all/european-working-conditions-survey-2024-overview-report>

de casos con valores perdidos en los controles, principalmente en las horas semanales esperadas. Por último, el uso de modelos de probabilidad lineal para las variables de salud binarias, aunque justificado por su robustez frente al diseño muestral complejo y las exposiciones poco frecuentes, constituye una simplificación; además, la relación de mediación entre esfuerzo y salud implícita en el planteamiento inicial no se ha contrastado de forma explícita, sino que ambas dimensiones se han modelizado en paralelo.

En conclusión, este trabajo permite ofrecer una respuesta a las tres preguntas de investigación planteadas. En cuanto a la primera, la adopción de la IA en Europa es todavía moderada y desigual, concentrada en las ocupaciones cualificadas, las grandes empresas y los países más avanzados. Respecto a la segunda, el efecto de la IA sobre el esfuerzo y la salud es heterogéneo y se concentra en las plataformas de cooperación, que se asocian con una mayor intensificación del trabajo y con un peor bienestar; la IA generativa apenas se vincula a una mayor presión por plazos y los cobots ofrecen un patrón débil. Y en relación con la tercera, los factores del contexto laboral influyen de forma apreciable en el esfuerzo y la salud (el país, el sector y el tamaño del centro de trabajo presentan asociaciones significativas, como recoge el apartado 4.8), mientras que el género y los intereses laborales del trabajador no moderan el efecto de la IA en la forma prevista, con la única excepción de la sensibilidad a la carga de trabajo en el uso de las plataformas.

La inteligencia artificial no se comporta, por tanto, como una amenaza uniforme para la calidad del empleo, sino como una fuerza contingente cuyas consecuencias dependen de cómo se implante y del contexto organizativo e individual en el que opera. Esta conclusión subraya la relevancia de las respuestas regulatorias y organizativas que se abordan en el apartado siguiente y apunta a la necesidad de futuras investigaciones de carácter longitudinal que permitan confirmar la dirección de las relaciones aquí identificadas.

6. IMPLICACIONES PRÁCTICAS

Los resultados de este trabajo no autorizan a prescribir medidas a partir de relaciones causales, dado el carácter transversal y observacional de los datos; sin embargo, sí permiten orientar la acción pública y organizativa a partir del patrón central que emerge del análisis: el impacto de la inteligencia artificial sobre las condiciones de trabajo no es uniforme, sino contingente. Una misma tecnología puede funcionar como demanda o como recurso en función del tipo de herramienta, de la dimensión afectada, del perfil y los intereses del trabajador y del contexto institucional y organizativo en que se implanta. De esta lógica

contingente, coherente con el modelo de Demandas y Recursos del Trabajo (JD-R) y con la teoría del Desequilibrio Esfuerzo-Recompensa (ERI), se derivan las implicaciones que se exponen a continuación, formuladas como orientaciones condicionadas y no como relaciones de causa-efecto.

6.1. Implicaciones para políticas públicas

La principal implicación regulatoria se deriva de la heterogeneidad de los efectos observados. Si la IA no produce un impacto único, sino que su signo y su intensidad dependen del tipo de tecnología, la respuesta normativa más adecuada no es un tratamiento uniforme, sino una regulación diferenciada por tipo de herramienta y nivel de riesgo. El Reglamento de Inteligencia Artificial (AI Act)²⁰ avanza en esta dirección al clasificar como de alto riesgo las herramientas destinadas a la gestión del rendimiento, la contratación o la evaluación de los trabajadores. Los resultados de este trabajo respaldan esa lógica de graduación, pero matizan dónde se concentra el riesgo: son las plataformas de cooperación y coordinación digital, y no la IA generativa ni los cobots, las que más se asocian a una intensificación del trabajo y a un peor bienestar. Una regulación eficaz debería, por tanto, prestar especial atención a las herramientas de coordinación y asignación digital del trabajo, en lugar de tratar la «IA» como una categoría homogénea o de centrar el foco únicamente en sus manifestaciones más mediáticas.

En coherencia con el perfil identificado en el análisis, una segunda línea de actuación debería reforzar la prevención de riesgos psicosociales asociados a la coordinación digital del trabajo. Las plataformas de cooperación, además de intensificar el ritmo y los plazos, se asocian con más ansiedad, peor sueño y más dolores de cabeza y musculares en la zona superior del cuerpo, un patrón que combina tensión psicológica con molestias físicas propias del trabajo intensivo ante pantallas. Ello aconseja integrar de forma explícita estas herramientas en los marcos de evaluación de riesgos laborales, atendiendo no solo a la carga cognitiva y al ritmo impuesto, sino también a la ergonomía del trabajo digital sostenido. Los cobots, cuya prevalencia es aún marginal, muestran un patrón de salud débil, sin

²⁰ Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial (Reglamento de Inteligencia Artificial). DOUE L, de 12 de julio de 2024. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj?locale=es>

asociaciones adversas claras, que aconseja mantener la vigilancia preventiva habitual²¹ sin sobredimensionar su riesgo a partir de los datos disponibles.

A diferencia de lo previsto, el análisis no encuentra un efecto diferenciado de la IA por género: la asociación entre exposición tecnológica y bienestar no difiere de forma significativa entre hombres y mujeres. Este resultado aconseja prudencia antes de asumir un impacto desigual por género de la digitalización a partir de la mera adopción, que sí difiere (los hombres usan más la IA generativa y los cobots, y las mujeres algo más las plataformas de cooperación). No obstante, el seguimiento de la adopción y de las condiciones de trabajo desagregado por sexo sigue siendo recomendable, dado que la intensidad del trabajo evoluciona de forma distinta para unos y otras según los indicadores de Eurofound²².

La gestión y coordinación algorítmica del trabajo constituye un cuarto ámbito de intervención, y es el que el análisis sitúa en primer plano. Una proporción elevada de trabajadores europeos está ya sujeta a la monitorización digital de sus horas y ritmos y a la asignación automatizada de tareas²³, un fenómeno conceptualizado por la literatura como un nuevo «terreno en disputa» del control en el trabajo²⁴. Los resultados de este estudio refuerzan esa preocupación: las plataformas de cooperación digital, lejos de comportarse como un recurso neutro, se asocian con un mayor ritmo, más estrés y peor salud. La acción pública debería, por tanto, extender a estas herramientas de coordinación las exigencias de transparencia, los límites a la intensificación y la vigilancia de los ritmos impuestos, junto a los derechos de explicación e impugnación de las decisiones automatizadas más intrusivas.

Por último, los descriptivos de adopción revelan una concentración del uso de la IA en las ocupaciones cualificadas, las grandes organizaciones y los países del norte y centro de Europa, con España en torno a la media europea y una clara brecha respecto del sur y el este. Esta distribución desigual del acceso justifica políticas de formación y recualificación dirigidas en especial a los trabajadores menos cualificados, así como mecanismos de apoyo

²¹ Agencia Europea para la Seguridad y la Salud en el Trabajo (EU-OSHA) (2022). *Advanced robotics and automation: Implications for occupational safety and health*. Oficina de Publicaciones de la Unión Europea, Luxemburgo. https://osha.europa.eu/sites/default/files/2022-06/Advanced_robotics_automation_implications.pdf

²² Eurofound (2026b). *European Working Conditions Survey 2024: Overview report*. Eurofound, Dublín. <https://www.eurofound.europa.eu/en/publications/all/european-working-conditions-survey-2024-overview-report>

²³ Gonzalez-Vazquez, I., Fernández-Macías, E., Wright, S. y Villani, D. (2025). *Digital monitoring, algorithmic management and the platformisation of work in Europe*. Joint Research Centre (JRC143072), Comisión Europea. <https://publications.jrc.ec.europa.eu/repository/handle/JRC143072>

²⁴ Kellogg, K. C., Valentine, M. A. y Christin, A. (2020). Algorithms at work: The new contested terrain of control. *Academy of Management Annals*, 14(1), 366–410. <https://doi.org/10.5465/annals.2018.0174>

a las regiones y empresas rezagadas, de modo que el acceso a la IA no amplíe las desigualdades existentes. Dado que el riesgo de intensificación se concentra en las plataformas de coordinación digital, considerablemente más extendidas que la IA generativa o los cobots, las políticas de calidad del empleo deberían vigilar de cerca precisamente la tecnología hoy más difundida, y no solo las de aparición más reciente.

6.2. Implicaciones para las organizaciones

Para las organizaciones, la lección central del análisis es que el carácter de la IA como demanda o como recurso depende en gran medida de cómo se implante, pero también de qué tecnología se trate. El dato más relevante es que las plataformas de cooperación digital, la herramienta hoy más extendida, se asocian con un mayor ritmo, más estrés y peor salud: su introducción no es neutra y, mal gestionada, opera como una demanda añadida. Las organizaciones que recurran a estas plataformas deberían acompañar su despliegue de los apoyos necesarios (formación, autonomía y respaldo de compañeros y superiores) y vigilar que la coordinación digital no se traduzca en una aceleración sostenida del trabajo.

De ello se desprende una segunda recomendación: evitar que las ganancias de eficiencia se traduzcan en una intensificación de los ritmos. El análisis asocia las plataformas de cooperación (y, en la dimensión de plazos, también la IA generativa) con una mayor presión temporal. Si el tiempo o la coordinación que estas herramientas facilitan se reabsorbe de inmediato en forma de mayores cargas y plazos más ajustados, se neutraliza su potencial y se añade tensión. Conviene, por tanto, que las mejoras de rendimiento que posibilita la tecnología respondan a la iniciativa del trabajador antes que a una presión impuesta por los ritmos del sistema.

En tercer lugar, allí donde las organizaciones recurran a sistemas de monitorización o coordinación algorítmica, la transparencia constituye un instrumento clave para reducir la opacidad y la percepción de control. Explicar qué se monitoriza y con qué lógica operan estos sistemas contribuye a transformar una posible fuente de tensión en una herramienta legítima a ojos de los empleados, y resulta especialmente pertinente dado que, en este estudio, son precisamente las plataformas de coordinación digital las que se asocian con un peor bienestar.

En cuarto lugar, el seguimiento interno de la intensidad del trabajo adquiere una relevancia particular. Dado que la asociación adversa se concentra en la coordinación digital y se manifiesta de forma simultánea en el ritmo, los plazos y el estrés, las organizaciones que

introduzcan estas plataformas harían bien en incorporar indicadores de carga e intensidad, y no solo de productividad, a su seguimiento habitual. De este modo, un aumento sostenido del ritmo o de la presión por plazos podría detectarse y corregirse antes de que derive en un deterioro del bienestar o en mayores tasas de absentismo y rotación. Medir únicamente las ganancias de eficiencia, sin vigilar su contrapartida en términos de tensión, ofrece una imagen incompleta del efecto real de la herramienta sobre la plantilla.

En quinto lugar, conviene atender a la dimensión física del trabajo digital, a menudo relegada frente a sus efectos psicológicos. En este estudio, el uso de plataformas de cooperación no solo se asocia con una mayor tensión psicológica, sino también con más dolores de cabeza y con molestias musculoesqueléticas en la zona superior del cuerpo, un perfil característico del trabajo intensivo y prolongado ante pantallas. Para las organizaciones, esta evidencia se traduce en medidas concretas y de coste reducido, como el diseño ergonómico de los puestos, la introducción de pausas regulares y la rotación de tareas, o la limitación de las jornadas de coordinación digital ininterrumpida. Atender a estos aspectos resulta tanto más pertinente cuanto que afecta a la tecnología hoy más extendida, presente ya en una proporción considerable de los puestos de trabajo europeos.

El análisis no respalda, en cambio, la existencia de un impacto diferencial de la IA sobre las mujeres: los efectos sobre el esfuerzo y la salud no difieren de forma significativa por género. Ello no exime a las organizaciones de cuidar la inclusión en el diseño y el despliegue de estas herramientas, pero sí desaconseja basar medidas específicas en un supuesto efecto adverso por género que los datos no confirman.

Finalmente, todas las recomendaciones anteriores convergen en un principio común: la adopción participativa. Puesto que el efecto de una misma tecnología depende de cómo se implante y de la dimensión del trabajo sobre la que incide, una implantación uniforme y de arriba abajo corre el riesgo de errar. Involucrar a los trabajadores en el diseño y la introducción de las herramientas de IA, y muy especialmente de las plataformas de coordinación que más se asocian con la intensificación, permite ajustar su despliegue a esa heterogeneidad y aprovechar su potencial como recurso, en lugar de añadir una nueva demanda a un entorno laboral ya tensionado.

7. BIBLIOGRAFÍA

- Adăscăliței, D., Heyes, J. y Mendonça, P. (2022). The intensification of work in Europe: A multilevel analysis. *British Journal of Industrial Relations*, 60(2), 324–347. <https://doi.org/10.1111/bjir.12611>
- Agencia Europea para la Seguridad y la Salud en el Trabajo (EU-OSHA). (2022). *Advanced robotics and automation: Implications for occupational safety and health*. Oficina de Publicaciones de la Unión Europea. https://osha.europa.eu/sites/default/files/2022-06/Advanced_robotics_automation_implications.pdf
- Avgoustaki, A. y Frankort, H. T. W. (2023). All work intensity is not created equal: Effort motives, job satisfaction and quit intentions at a grocery chain. *British Journal of Industrial Relations*, 61(4), 869–894. <https://doi.org/10.1111/bjir.12724>
- Bakker, A. B. y 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>
- Bick, A., Blandin, A. y Deming, D. (2025). *The impact of generative AI on work productivity*. Federal Reserve Bank of St. Louis. <https://www.stlouisfed.org/on-the-economy/2025/feb/impact-generative-ai-work-productivity>
- Eurofound. (2026a). *European Working Conditions Survey, 2024* [conjunto de datos]. UK Data Service. SN: 9511. <https://doi.org/10.5255/UKDA-SN-9511-1>
- Eurofound. (2026b). *European Working Conditions Survey 2024: Overview report*. Eurofound. <https://www.eurofound.europa.eu/en/publications/all/european-working-conditions-survey-2024-overview-report>
- Geary, J. y Wilson, L. (2023). *Job quality in Ireland*. Nevin Economic Research Institute (NERI). <https://www.neriinstitute.net/sites/default/files/research/Job%20quality%20in%20Ireland.pdf>
- Gong, Q., Fan, D. y Bartram, T. (2025). Integrating artificial intelligence and human resource management: A review and future research agenda. *The International*

Journal of Human Resource Management, 36(1), 103–141.

<https://doi.org/10.1080/09585192.2024.2440065>

Gonzalez-Vazquez, I., Fernández-Macías, E., Wright, S. y Villani, D. (2025). *Digital monitoring, algorithmic management and the platformisation of work in Europe*. Joint Research Centre (JRC143072), Comisión Europea.

<https://publications.jrc.ec.europa.eu/repository/handle/JRC143072>

Kellogg, K. C., Valentine, M. A. y Christin, A. (2020). Algorithms at work: The new contested terrain of control. *Academy of Management Annals*, 14(1), 366–410.

<https://doi.org/10.5465/annals.2018.0174>

Lumley, T. (2010). *Complex surveys: A guide to analysis using R*. Wiley.

OCDE. (2023). *OECD Employment Outlook 2023: Artificial intelligence and the labour market*. OECD Publishing. <https://doi.org/10.1787/08785bba-en>

Penn Wharton Budget Model. (2025). *The projected impact of generative AI on future productivity growth*. University of Pennsylvania.

<https://budgetmodel.wharton.upenn.edu/p/2025-09-08-the-projected-impact-of-generative-ai-on-future-productivity-growth/>

Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial (Reglamento de Inteligencia Artificial). DOUE L, 12 de julio de 2024.

<https://eur-lex.europa.eu/eli/reg/2024/1689/oj?locale=es>

Siegrist, J. (1996). Adverse health effects of high-effort/low-reward conditions. *Journal of Occupational Health Psychology*, 1(1), 27–41. [https://doi.org/10.1037/1076-](https://doi.org/10.1037/1076-8998.1.1.27)

[8998.1.1.27](https://doi.org/10.1037/1076-8998.1.1.27)

Anexo de código

Script 1: Análisis Principal

1.1 Instalación y carga de paquetes

```
install.packages(c("survey", "tidyverse", "stargazer"))

library(survey)
library(tidyverse)
library(stargazer)
```

1.2 Carga de datos

```
ruta_datos <- "/Users/pablomartinhuidobro/Desktop/docs encuesta/"

datos_raw <- readRDS("/Users/pablomartinhuidobro/Desktop/docs
encuesta/ewcs24_dataset_ukds.rds")

cat("Observaciones:", nrow(datos_raw), "| Variables:", ncol(datos_raw), "\n")
```

1.3 Limpieza y recodificación de variables

```
# Convertir variables haven_labelled a numérico
datos_raw <- datos_raw %>% mutate(across(where(haven::is.labelled), as.numeric))

datos <- datos_raw %>%
  mutate(

    # Variables independientes (1=Sí, 2=No → 1/0)
    tech_genAI = ifelse(tech_genAI == 1, 1,
                        ifelse(tech_genAI == 2, 0, NA)),
    tech_coopplatforms = ifelse(tech_coopplatforms == 1, 1,
                                ifelse(tech_coopplatforms == 2, 0, NA)),
    tech_cobots = ifelse(tech_cobots == 1, 1,
                         ifelse(tech_cobots == 2, 0, NA)),

    # DVs esfuerzo: escala 1-7 invertida
    highspeed_r = 8 - highspeed, # 7 = siempre a ritmo elevado
    tightdead_r = 8 - tightdead, # 7 = siempre con plazos ajustados
    # DVs estrés: escala 1-5 invertida
    stress_r = 6 - stress, # 5 = siempre estresado

    # DVs salud: binarias (1=Sí, 2=No → 1/0)
    health_anxiety_r = ifelse(health_anxiety == 1, 1,
                              ifelse(health_anxiety == 2, 0, NA)),
    health_backache_r = ifelse(health_backache == 1, 1,
                                ifelse(health_backache == 2, 0, NA)),
    health_headaches_r = ifelse(health_headaches == 1, 1,
                                 ifelse(health_headaches == 2, 0, NA)),
    health_musc_upper_r = ifelse(health_musc_upper == 1, 1,
                                 ifelse(health_musc_upper == 2, 0, NA)),
    health_musc_lower_r = ifelse(health_musc_lower == 1, 1,
                                 ifelse(health_musc_lower == 2, 0, NA)),
```

```

sleeping_r = 5 - sleeping_difficulties, # 4 = dificultades diarias
selfhealth_r = selfrated_health, # 1 = muy buena, 5 = muy mala

# Variables de control
seniority = ifelse(seniority == -555, 0.5, seniority),
seniority = ifelse(!is.na(seniority) & !is.na(age) & seniority > (age -
14), NA_real_, seniority),
expected_hours_week = ifelse(expected_hours_week < 1 | expected_hours_week >
90,
NA_real_, expected_hours_week),
country = as.factor(country),
occupation = as.factor(occupation),
sector = as.factor(sector),
wp_size = as.factor(wp_size),
age_bands = cut(age,
breaks = c(15, 24, 34, 44, 54, 64, 74),
labels = c("16-24", "25-34", "35-44", "45-54", "55-64", "65-
74")),
right = TRUE),

# Variables moderadoras: escala 1-4 invertida (4 = muy importante)
goodjob_workload_r = 5 - goodjob_workload,
goodjob_aut_r = 5 - goodjob_aut,
goodjob_safe_r = 5 - goodjob_safe,
goodjob_secureempl_r = 5 - goodjob_secureempl,
goodjob_wlb_r = 5 - goodjob_wlb,
fair_treatment_r = 6 - fair_treatment # 5 = trato siempre justo
)

cat("\nDistribucion IVs (% uso de tecnologia):\n")
cat(" IA Generativa: ", round(mean(datos$tech_genAI, na.rm=TRUE)*100,
1), "%\n")
cat(" Plataformas cooperacion:", round(mean(datos$tech_coopplatforms,
na.rm=TRUE)*100, 1), "%\n")
cat(" Cobots: ", round(mean(datos$tech_cobots, na.rm=TRUE)*100,
1), "%\n")

```

1.4 Definición del diseño muestral complejo

```

options(survey.lonely.psu = "adjust")

diseno <- svydesign(
  ids = ~samplingpointid,
  strata = ~stratumid,
  weights = ~calweight,
  data = datos,
  nest = TRUE
)

cat("Diseno muestral definido correctamente.\n")

```

1.5 Análisis descriptivo — Adopción tecnológica (PI1)

```

# Adopción global
adopcion_global <- svymean(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  diseno, na.rm = TRUE
)
print(round(coef(adopcion_global) * 100, 1))

# Por género

```

```

adopcion_genero <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~sex2, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_genero[, 2:4] * 100, 1))

# Por ocupación
adopcion_ocupacion <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~occupation, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_ocupacion[, 2:4] * 100, 1))

# Por sector
adopcion_sector <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~sector, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_sector[, 2:4] * 100, 1))

# Por país
adopcion_pais <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~country, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_pais[, 2:4] * 100, 1))

# Por tamaño de empresa
adopcion_wp_size <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~wp_size, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_wp_size[, 2:4] * 100, 1))

# Por tramo de edad
adopcion_edad <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~age_bands, disenno, svymean, na.rm = TRUE
)
print(round(adopcion_edad[, 2:4] * 100, 1))

write.csv(round(adopcion_pais[, 2:4] * 100, 1),
  paste0(ruta_datos, "desc_adopcion_pais.csv"))
write.csv(round(adopcion_wp_size[, 2:4] * 100, 1),
  paste0(ruta_datos, "desc_adopcion_wp_size.csv"))
write.csv(round(adopcion_edad[, 2:4] * 100, 1),
  paste0(ruta_datos, "desc_adopcion_edad.csv"))

```

1.6 Modelos H1 — Esfuerzo e intensidad laboral

```

controles <- "+ sex2 + age_bands + country + seniority +
  occupation + sector + wp_size + expected_hours_week"

# H1a: esfuerzo intensivo
m_highspeed <- svyglm(
  as.formula(paste("highspeed_r ~ tech_genAI + tech_coopplatforms + tech_cobots",
    controles)),
  design = disenno, family = gaussian()
)
m_tightdead <- svyglm(
  as.formula(paste("tightdead_r ~ tech_genAI + tech_coopplatforms + tech_cobots",
    controles)),
  design = disenno, family = gaussian()
)

```

```

)
m_stress <- svyglm(
  as.formula(paste("stress_r ~ tech_genAI + tech_coopplatforms + tech_cobots",
    controles)),
  design = disenno, family = gaussian()
)

print(round(summary(m_highspeed)$coefficients[2:4, ], 4))
print(round(summary(m_tightdead)$coefficients[2:4, ], 4))
print(round(summary(m_stress)$coefficients[2:4, ], 4))

# H1b: salud
m_anxiety <- svyglm(
  as.formula(paste("health_anxiety_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)
m_sleep <- svyglm(
  as.formula(paste("sleeping_r ~ tech_genAI + tech_coopplatforms + tech_cobots",
    controles)),
  design = disenno, family = gaussian()
)
m_selfhealth <- svyglm(
  as.formula(paste("selfhealth_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)
m_headaches <- svyglm(
  as.formula(paste("health_headaches_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)
m_musc_upper <- svyglm(
  as.formula(paste("health_musc_upper_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)
m_musc_lower <- svyglm(
  as.formula(paste("health_musc_lower_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)
m_backache <- svyglm(
  as.formula(paste("health_backache_r ~ tech_genAI + tech_coopplatforms +
    tech_cobots", controles)),
  design = disenno, family = gaussian()
)

print(round(summary(m_anxiety)$coefficients[2:4, ], 4))
print(round(summary(m_sleep)$coefficients[2:4, ], 4))
print(round(summary(m_selfhealth)$coefficients[2:4, ], 4))

# P-valores corregidos (distribución normal)
pval_svyglm <- function(modelo) {
  coefs <- summary(modelo)$coefficients
  pvals <- 2 * pnorm(-abs(coefs[, "t value"]))
  cbind(coefs[, 1:3], "p-valor" = round(pvals, 4))
}

print(pval_svyglm(m_highspeed)[2:4, ])
print(pval_svyglm(m_tightdead)[2:4, ])
print(pval_svyglm(m_stress)[2:4, ])
print(pval_svyglm(m_anxiety)[2:4, ])
print(pval_svyglm(m_selfhealth)[2:4, ])

```

1.7 Modelos H2 — Moderación por género

```
# Interacciones tecnología × género
m_stress_genero <- svyglm(
  as.formula(paste("stress_r ~ tech_genAI*sex2 + tech_coopplatforms*sex2 +
tech_cobots*sex2", controles)),
  design = diseno, family = gaussian()
)
m_anxiety_genero <- svyglm(
  as.formula(paste("health_anxiety_r ~ tech_genAI*sex2 + tech_coopplatforms*sex2 +
tech_cobots*sex2", controles)),
  design = diseno, family = gaussian()
)
m_selfhealth_genero <- svyglm(
  as.formula(paste("selfhealth_r ~ tech_genAI*sex2 + tech_coopplatforms*sex2 +
tech_cobots*sex2", controles)),
  design = diseno, family = gaussian()
)

coefs_h2 <- summary(m_stress_genero)$coefficients
print(round(coefs_h2[grepl(":", rownames(coefs_h2))], ], 4))

coefs_h2b <- summary(m_anxiety_genero)$coefficients
print(round(coefs_h2b[grepl(":", rownames(coefs_h2b))], ], 4))
```

1.8 Modelos H3 — Moderación por valores laborales

```
# Moderación por valores laborales
m_h3_workload <- svyglm(
  as.formula(paste(
    "stress_r ~ tech_genAI*goodjob_workload_r +
tech_coopplatforms*goodjob_workload_r +
tech_cobots*goodjob_workload_r", controles)),
  design = diseno, family = gaussian()
)
m_h3_aut <- svyglm(
  as.formula(paste(
    "stress_r ~ tech_genAI*goodjob_aut_r + tech_coopplatforms*goodjob_aut_r +
tech_cobots*goodjob_aut_r", controles)),
  design = diseno, family = gaussian()
)
m_h3_fair <- svyglm(
  as.formula(paste(
    "health_anxiety_r ~ tech_genAI*fair_treatment_r +
tech_coopplatforms*fair_treatment_r +
tech_cobots*fair_treatment_r", controles)),
  design = diseno, family = gaussian()
)
m_h3_security <- svyglm(
  as.formula(paste(
    "health_anxiety_r ~ tech_genAI*goodjob_secureempl_r +
tech_coopplatforms*goodjob_secureempl_r +
tech_cobots*goodjob_secureempl_r", controles)),
  design = diseno, family = gaussian()
)

c3a <- summary(m_h3_workload)$coefficients
print(round(c3a[grepl(":", rownames(c3a))], ], 4))

c3b <- summary(m_h3_aut)$coefficients
print(round(c3b[grepl(":", rownames(c3b))], ], 4))

c3c <- summary(m_h3_fair)$coefficients
print(round(c3c[grepl(":", rownames(c3c))], ], 4))
```

1.9 Exportación de resultados

```
extraer_coef <- function(modelo, nombre_dv) {
  coefs <- as.data.frame(summary(modelo)$coefficients)
  coefs$variable <- rownames(coefs)
  coefs$dependiente <- nombre_dv
  rownames(coefs) <- NULL
  coefs
}

# Tabla 1: descriptivos
vars_tabla1 <- c("tech_genAI", "tech_coopplatforms", "tech_cobots",
                "highspeed_r", "tightdead_r", "stress_r",
                "health_anxiety_r", "sleeping_r", "selfhealth_r")
tabla1 <- do.call(rbind, lapply(vars_tabla1, function(v) {
  m <- svymean(as.formula(paste0("~", v)), diseno, na.rm = TRUE)
  data.frame(variable = v,
              media = round(as.numeric(coef(m)), 3),
              se = round(as.numeric(SE(m)), 3))
}))
write.csv(tabla1, paste0(ruta_datos, "tabla1_descriptivos.csv"), row.names =
FALSE)

# Tabla 2: H1 esfuerzo
tabla2 <- bind_rows(
  extraer_coef(m_highspeed, "highspeed"),
  extraer_coef(m_tightdead, "tightdead"),
  extraer_coef(m_stress, "stress")
) %>% filter(variable %in%
c("(Intercept)", "tech_genAI", "tech_coopplatforms", "tech_cobots"))
write.csv(tabla2, paste0(ruta_datos, "tabla2_H1_esfuerzo.csv"), row.names =
FALSE)

# Tabla 3: H1 salud
tabla3 <- bind_rows(
  extraer_coef(m_anxiety, "ansiedad"),
  extraer_coef(m_sleep, "sueno"),
  extraer_coef(m_selfhealth, "salud_general"),
  extraer_coef(m_headaches, "dolor_cabeza"),
  extraer_coef(m_musc_upper, "musc_superior"),
  extraer_coef(m_musc_lower, "musc_inferior"),
  extraer_coef(m_backache, "espalda")
) %>% filter(variable %in%
c("(Intercept)", "tech_genAI", "tech_coopplatforms", "tech_cobots"))
write.csv(tabla3, paste0(ruta_datos, "tabla3_H1_salud.csv"), row.names = FALSE)

# Tabla 4: H2 género
tabla4 <- bind_rows(
  extraer_coef(m_stress_genero, "stress"),
  extraer_coef(m_anxiety_genero, "ansiedad"),
  extraer_coef(m_selfhealth_genero, "salud_general")
) %>% filter(grepl("tech_|sex2", variable))
write.csv(tabla4, paste0(ruta_datos, "tabla4_H2_genero.csv"), row.names = FALSE)

# Tabla 5: H3 moderación
tabla5 <- bind_rows(
  extraer_coef(m_h3_workload, "stress_workload"),
  extraer_coef(m_h3_aut, "stress_autonomia"),
  extraer_coef(m_h3_fair, "ansiedad_trato"),
  extraer_coef(m_h3_security, "ansiedad_seguridad")
) %>% filter(grepl(":", variable))
write.csv(tabla5, paste0(ruta_datos, "tabla5_H3_moderacion.csv"), row.names =
FALSE)
```

1.10 Gráficos

```
# Gráfico 1: adopción por género
adopt_gen_df <- as.data.frame(adopcion_genero) %>%
  select(sex2, tech_genAI, tech_coopplatforms, tech_cobots) %>%
  pivot_longer(-sex2, names_to = "tecnologia", values_to = "porcentaje") %>%
  mutate(
    tecnologia = dplyr::recode(tecnologia,
                              "tech_genAI" = "IA Generativa",
                              "tech_coopplatforms" = "Plataformas\ncoop",
                              "tech_cobots" = "Robots\ncolaborativos"),
    porcentaje = porcentaje * 100
  )

g1 <- ggplot(adopt_gen_df, aes(x = tecnologia, y = porcentaje, fill = sex2)) +
  geom_col(position = "dodge", width = 0.6) +
  scale_fill_manual(values = c("#2E5090", "#E07B39"), name = "Genero") +
  geom_text(aes(label = paste0(round(porcentaje, 1), "%"),
                 position = position_dodge(0.6), vjust = -0.4, size = 3.5) +
  labs(title = NULL, subtitle = NULL, x = "", y = "% trabajadores") +
  theme_minimal(base_size = 12) +
  theme(legend.position = "top", plot.title = element_text(face = "bold"))

ggsave(paste0(ruta_datos, "grafico1_adopcion_genero.png"), g1,
        width = 8, height = 6, dpi = 300)

# Gráfico 2: coeficientes con intervalos de confianza (IC 95%)
coef_resumen <- bind_rows(
  extraer_coef(m_stress, "Estres"),
  extraer_coef(m_highspeed, "Ritmo elevado"),
  extraer_coef(m_anxiety, "Ansiedad"),
  extraer_coef(m_selfhealth, "Salud general")
) %>%
  filter(variable %in% c("tech_genAI", "tech_coopplatforms", "tech_cobots")) %>%
  rename(coef = Estimate, se = `Std. Error`, tval = `t value`) %>%
  mutate(
    pval = 2 * pnorm(-abs(tval)),
    variable = dplyr::recode(variable,
                              "tech_genAI" = "IA Generativa",
                              "tech_coopplatforms" = "Plataformas coop.",
                              "tech_cobots" = "Cobots"),
    sig = ifelse(pval < 0.05, "p < 0.05", "No significativo")
  )

g2 <- ggplot(coef_resumen,
  aes(x = coef, y = variable, color = sig,
      xmin = coef - 1.96*se, xmax = coef + 1.96*se)) +
  geom_pointrange(size = 0.8) +
  geom_vline(xintercept = 0, linetype = "dashed", color = "grey50") +
  scale_color_manual(values = c("p < 0.05" = "#2E5090",
                                "No significativo" = "#AAAAAA"), name = "") +
  facet_wrap(~dependiente, scales = "free_x") +
  labs(title = "Efecto de la exposicion tecnologica (IC 95%)",
        subtitle = "Modelos svyglm - EWCS 2024",
        x = "Coeficiente estimado", y = "") +
  theme_minimal(base_size = 11) +
  theme(legend.position = "bottom", plot.title = element_text(face = "bold"),
        strip.text = element_text(face = "bold"))

ggsave(paste0(ruta_datos, "grafico2_coeficientes_H1.png"), g2,
        width = 10, height = 7, dpi = 300)
```

Script 2: Descriptivos Adicionales

2.1 Adopción por país

```
adopcion_pais <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~country, diseno, svymean, na.rm = TRUE
)

pais_labels <- c(
  "1"="Austria", "2"="Bélgica", "3"="Bulgaria", "4"="Croacia", "5"="Chipre",
  "6"="Chequia", "7"="Dinamarca", "8"="Estonia", "9"="Finlandia", "10"="Francia",
  "11"="Alemania", "12"="Grecia", "13"="Hungria", "14"="Irlanda", "15"="Italia",
  "16"="Letonia", "17"="Lituania", "18"="Luxemburgo", "19"="Malta", "20"="Países
Bajos",
  "21"="Noruega", "22"="Polonia", "23"="Portugal", "24"="Rumanía", "25"="Eslovaquia",
  "26"="Eslovenia", "27"="España", "28"="Suecia", "29"="Suiza", "30"="Albania",
  "31"="Bosnia-Herzegovina", "32"="Macedonia del Norte", "33"="Kosovo",
  "34"="Montenegro", "35"="Serbia"
)

tabla_pais <- round(adopcion_pais[, 2:4] * 100, 1)
rownames(tabla_pais) <- pais_labels[as.character(rownames(tabla_pais))]
colnames(tabla_pais) <- c("IA Generativa (%)", "Plat. Cooperación (%)", "Cobots
(%)" )

# Ordenado descendente por adopción de IA Generativa
print(tabla_pais[order(-tabla_pais[,1]), ])
write.csv(tabla_pais[order(-tabla_pais[,1]), ],
          paste0(ruta_datos, "desc_adopcion_pais.csv"))
```

2.2 Adopción por tamaño de empresa

```
adopcion_wp_size <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~wp_size, diseno, svymean, na.rm = TRUE
)

tabla_wp <- round(adopcion_wp_size[, 2:4] * 100, 1)
rownames(tabla_wp) <- c("Solo trabajador/a", "2-4 empleados", "5-9 empleados",
  "10-49 empleados", "50-99 empleados", "100-249 empleados",
  "250-499 empleados", "500 o más empleados")
colnames(tabla_wp) <- c("IA Generativa (%)", "Plat. Cooperación (%)", "Cobots
(%)" )

print(tabla_wp)
write.csv(tabla_wp, paste0(ruta_datos, "desc_adopcion_wp_size.csv"))
```

2.3 Adopción por tramo de edad

```
adopcion_edad <- svyby(
  ~tech_genAI + tech_coopplatforms + tech_cobots,
  ~age_bands, diseno, svymean, na.rm = TRUE
)
```

```

tabla_edad <- round(adopcion_edad[, 2:4] * 100, 1)
rownames(tabla_edad) <- c("16-24 años", "25-34 años", "35-44 años",
                          "45-54 años", "55-64 años", "65-74 años")
colnames(tabla_edad) <- c("IA Generativa (%)", "Plat. Cooperación (%)", "Cobots (%)")

print(tabla_edad)
write.csv(tabla_edad, paste0(ruta_datos, "desc_adopcion_edad.csv"))

```

Script 3: Análisis Adicionales

3.1 Paquetes adicionales

```
#install.packages(c("car", "ggcorrplot", "reshape2"))

library(car)
library(ggcorrplot)
library(reshape2)
library(tidyverse)
```

3.2 Estadísticos descriptivos completos

```
vars_todas <- c(
  "tech_genAI", "tech_coopplatforms", "tech_cobots",
  "highspeed_r", "tightdead_r", "stress_r",
  "health_anxiety_r", "health_backache_r", "health_headaches_r",
  "health_musc_upper_r", "health_musc_lower_r", "sleeping_r", "selfhealth_r",
  "goodjob_workload_r", "goodjob_aut_r", "goodjob_safe_r",
  "goodjob_secureempl_r", "goodjob_wlb_r", "fair_treatment_r"
)

etiquetas <- c(
  "IA Generativa (0/1)", "Plataformas cooperación (0/1)", "Robots colaborativos - Cobots (0/1)",
  "Ritmo elevado de trabajo (1-7)", "Plazos ajustados (1-7)", "Estrés laboral (1-5)",
  "Ansiedad (0/1)", "Dolor de espalda (0/1)", "Dolor de cabeza (0/1)",
  "Dolor muscular superior (0/1)", "Dolor muscular inferior (0/1)",
  "Dificultades sueño (1-4)", "Salud autoevaluada (1-5)",
  "Importancia carga manejable (1-4)", "Importancia autonomía (1-4)",
  "Importancia entorno seguro (1-4)", "Importancia seguridad laboral (1-4)",
  "Importancia conciliación (1-4)", "Trato justo en el trabajo (1-5)"
)

bloque <- c(
  rep("Variable independiente", 3),
  rep("Variable dependiente - Esfuerzo", 3),
  rep("Variable dependiente - Salud", 7),
  rep("Variable moderadora", 6)
)

# Estadísticos ponderados por variable (evita borrado por lista)
desc_por_var <- do.call(rbind, lapply(vars_todas, function(v){
  m <- svymean(as.formula(paste0("~", v)), diseno, na.rm = TRUE)
  vr <- svyvar(as.formula(paste0("~", v)), diseno, na.rm = TRUE)
  data.frame(
    N      = sum(!is.na(datos[[v]])),
    Media  = round(as.numeric(coef(m)), 3),
    SE     = round(as.numeric(SE(m)), 3),
    SD     = round(sqrt(as.numeric(coef(vr))), 3)
  )
}))

tabla_desc <- data.frame(
  Bloque    = bloque,
  Variable  = vars_todas,
  Etiqueta  = etiquetas,
  N         = desc_por_var$N,
```

```

Media      = desc_por_var$Media,
SE         = desc_por_var$SE,
SD         = desc_por_var$SD
)
write.csv(tabla_desc,
          paste0(ruta_datos, "tablaA_descriptivos_completos.csv"),
          row.names = FALSE)
print(tabla_desc)

```

3.3 Diagnóstico de multicolinealidad (VIF)

```

# VIF calculado con lm() (car::vif no admite bien svyglm con factores de muchos
niveles)
# Se excluye 'country' por aliasing con sus 35 niveles
formula_vif <- as.formula("stress_r ~ tech_genAI + tech_coopplatforms +
tech_cobots +
                           sex2 + age_bands + seniority + occupation + sector +
                           wp_size + expected_hours_week")

datos_vif <- datos %>%
  select(stress_r, tech_genAI, tech_coopplatforms, tech_cobots,
         sex2, age_bands, seniority, occupation, sector,
         wp_size, expected_hours_week) %>%
  drop_na()

m_vif_lm <- lm(formula_vif, data = datos_vif)
vif_valores <- vif(m_vif_lm)
print(round(vif_valores, 3))

tabla_vif <- data.frame(
  Variable      = rownames(vif_valores),
  GVIF          = round(vif_valores[, 1], 3),
  GL            = vif_valores[, 2],
  GVIF_adj      = round(vif_valores[, 3], 3)
)
write.csv(tabla_vif,
          paste0(ruta_datos, "tablaB_VIF.csv"),
          row.names = FALSE)

```

3.4 Matriz de correlación de Spearman

```

vars_cor <- c(
  "tech_genAI", "tech_coopplatforms", "tech_cobots",
  "highspeed_r", "tightdead_r", "stress_r",
  "health_anxiety_r", "sleeping_r", "selfhealth_r",
  "health_headaches_r", "health_musc_upper_r", "health_musc_lower_r",
  "health_backache_r"
)

etiquetas_cor <- c(
  "IA Generativa", "Plat. coop.", "Cobots",
  "Ritmo elevado", "Plazos ajust.", "Estrés",
  "Ansiedad", "Sueño", "Salud gral.",
  "Dolor cabeza", "Musc. sup.", "Musc. inf.", "Espalda"
)

datos_cor <- datos %>%
  select(all_of(vars_cor)) %>%
  drop_na()

```

```

cor_mat <- cor(datos_cor, method = "spearman")
colnames(cor_mat) <- rownames(cor_mat) <- etiquetas_cor

write.csv(as.data.frame(cor_mat),
          paste0(ruta_datos, "tablaC_correlacion_spearman.csv"))

# Heatmap completo
g_corr_full <- ggcorrplot(
  cor_mat,
  method = "square",
  type = "lower",
  lab = TRUE,
  lab_size = 2.8,
  colors = c("#E07B39", "white", "#2E5090"),
  title = "",
  ggtheme = theme_minimal(base_size = 11),
  tl.cex = 10,
  tl.srt = 45
) +
  theme(
    plot.title = element_text(face = "bold", size = 12),
    legend.title = element_text(size = 9)
  )

ggsave(paste0(ruta_datos, "grafico3_correlacion_spearman.png"),
        g_corr_full, width = 13, height = 11, dpi = 300)

# Heatmap IVs vs DVs
vars_iv <- c("IA Generativa", "Plat. coop.", "Cobots")
vars_dv <- c("Ritmo elevado", "Plazos ajust.", "Estrés",
             "Ansiedad", "Sueño", "Salud gral.",
             "Dolor cabeza", "Musc. sup.", "Musc. inf.", "Espalda")

cor_iv_dv <- cor_mat[vars_iv, vars_dv]

cor_df <- melt(cor_iv_dv)
colnames(cor_df) <- c("IV", "DV", "Correlacion")

g_corr_iv_dv <- ggplot(cor_df, aes(x = DV, y = IV, fill = Correlacion)) +
  geom_tile(color = "white", size = 0.5) +
  geom_text(aes(label = round(Correlacion, 2)),
            size = 3.5, color = "black") +
  scale_fill_gradient2(
    low = "#E07B39",
    mid = "white",
    high = "#2E5090",
    midpoint = 0,
    limits = c(-0.3, 0.3),
    name = "Correlación\nde Spearman"
  ) +
  labs(title = NULL, subtitle = NULL, x = "", y = "") +
  theme_minimal(base_size = 12) +
  theme(
    axis.text.x = element_text(angle = 45, hjust = 1, size = 10),
    axis.text.y = element_text(size = 10),
    plot.title = element_text(face = "bold", size = 12),
    plot.subtitle = element_text(size = 10, color = "grey40"),
    legend.position = "right"
  )

ggsave(paste0(ruta_datos, "grafico4_correlacion_iv_dv.png"),
        g_corr_iv_dv, width = 12, height = 5, dpi = 300)

```

3.5 Tablas de regresión unificadas

```
extraer_resultado <- function(modelo, nombre_dv) {
  coefs <- as.data.frame(summary(modelo)$coefficients)
  pvals <- 2 * pnorm(-abs(coefs[, "t value"]))
  sig <- ifelse(pvals < 0.001, "****",
               ifelse(pvals < 0.01, "***",
                     ifelse(pvals < 0.05, "**",
                           ifelse(pvals < 0.1, "+", ""))))
  data.frame(
    variable = rownames(coefs),
    dependiente = nombre_dv,
    coef = round(coefs$Estimate, 4),
    se = round(coefs$`Std. Error`, 4),
    t_value = round(coefs$`t value`, 3),
    p_valor = round(pvals, 4),
    sig = sig,
    resultado = paste0(round(coefs$Estimate, 3), sig,
                      " (", round(coefs$`Std. Error`, 3), ")")
  )
}

ivs_nombres <- c("tech_genAI", "tech_coopplatforms", "tech_cobots")

# D1: H1 esfuerzo
res_esfuerzo <- bind_rows(
  extraer_resultado(m_highspeed, "Ritmo elevado"),
  extraer_resultado(m_tightdead, "Plazos ajustados"),
  extraer_resultado(m_stress, "Estrés")
) %>% filter(variable %in% ivs_nombres)

tabla_h1_wide <- res_esfuerzo %>%
  select(variable, dependiente, resultado) %>%
  pivot_wider(names_from = dependiente, values_from = resultado) %>%
  mutate(variable = dplyr::recode(variable,
    "tech_genAI" = "IA Generativa (tech_genAI)",
    "tech_coopplatforms" = "Plataformas cooperación (tech_coopplatforms)",
    "tech_cobots" = "Cobots (tech_cobots)"
  ))

write.csv(tabla_h1_wide,
  paste0(ruta_datos, "tablaD1_H1_esfuerzo_unificada.csv"),
  row.names = FALSE)
print(tabla_h1_wide)

# D2: H1 salud
res_salud <- bind_rows(
  extraer_resultado(m_anxiety, "Ansiedad"),
  extraer_resultado(m_sleep, "Sueño"),
  extraer_resultado(m_selfhealth, "Salud general"),
  extraer_resultado(m_headaches, "Dolor cabeza"),
  extraer_resultado(m_musc_upper, "Musc. superior"),
  extraer_resultado(m_musc_lower, "Musc. inferior"),
  extraer_resultado(m_backache, "Espalda")
) %>% filter(variable %in% ivs_nombres)

tabla_h1_salud_wide <- res_salud %>%
  select(variable, dependiente, resultado) %>%
  pivot_wider(names_from = dependiente, values_from = resultado) %>%
  mutate(variable = dplyr::recode(variable,
    "tech_genAI" = "IA Generativa (tech_genAI)",
    "tech_coopplatforms" = "Plataformas cooperación (tech_coopplatforms)",
    "tech_cobots" = "Cobots (tech_cobots)"
  ))
```

```

))

write.csv(tabla_h1_salud_wide,
          paste0(ruta_datos, "tablaD2_H1_salud_unificada.csv"),
          row.names = FALSE)
print(tabla_h1_salud_wide)

# D3: H2 género
res_genero <- bind_rows(
  extraer_resultado(m_stress_genero,      "Estrés"),
  extraer_resultado(m_anxiety_genero,     "Ansiedad"),
  extraer_resultado(m_selfhealth_genero,  "Salud general")
) %>% filter(grepl(":", variable))

tabla_h2_wide <- res_genero %>%
  select(variable, dependiente, resultado) %>%
  pivot_wider(names_from = dependiente, values_from = resultado) %>%
  mutate(variable = dplyr::recode(variable,
    "tech_genAI:sex2Female"      = "IA Gen. × Mujer",
    "sex2Female:tech_coopplatforms" = "Plat. coop. × Mujer",
    "sex2Female:tech_cobots"     = "Cobots × Mujer"
  ))

write.csv(tabla_h2_wide,
          paste0(ruta_datos, "tablaD3_H2_genero_unificada.csv"),
          row.names = FALSE)
print(tabla_h2_wide)

# D4: H3 moderación
res_mod <- bind_rows(
  extraer_resultado(m_h3_workload,      "Estrés × Carga"),
  extraer_resultado(m_h3_aut,           "Estrés × Autonomía"),
  extraer_resultado(m_h3_fair,          "Ansiedad × Trato"),
  extraer_resultado(m_h3_security,      "Ansiedad × Seguridad")
) %>% filter(grepl(":", variable))

write.csv(res_mod,
          paste0(ruta_datos, "tablaD4_H3_moderacion_unificada.csv"),
          row.names = FALSE)

```

3.6 Forest plot completo H1

```

todos_coef <- bind_rows(
  extraer_resultado(m_highspeed,      "Ritmo elevado"),
  extraer_resultado(m_tightdead,     "Plazos ajustados"),
  extraer_resultado(m_stress,        "Estrés"),
  extraer_resultado(m_anxiety,       "Ansiedad"),
  extraer_resultado(m_sleep,         "Sueño"),
  extraer_resultado(m_selfhealth,    "Salud general"),
  extraer_resultado(m_headaches,     "Dolor cabeza"),
  extraer_resultado(m_musc_upper,    "Musc. superior"),
  extraer_resultado(m_musc_lower,    "Musc. inferior"),
  extraer_resultado(m_backache,      "Espalda")
) %>%
  filter(variable %in% ivs_nombres) %>%
  mutate(
    variable = dplyr::recode(variable,
      "tech_genAI"      = "IA Generativa",
      "tech_coopplatforms" = "Plataformas coop.",
      "tech_cobots"     = "Cobots"
    ),

```

```

    grupo = ifelse(dependiente %in% c("Ritmo elevado", "Plazos
ajustados", "Estrés"),
                    "Esfuerzo intensivo", "Salud y bienestar"),
    sig_label = ifelse(p_valor < 0.05, "p < 0.05", "No significativo")
  )

g_forest <- ggplot(todos_coef,
                  aes(x = coef, y = variable,
                      xmin = coef - 1.96*se,
                      xmax = coef + 1.96*se,
                      color = sig_label)) +
  geom_pointrange(size = 0.7, linewidth = 0.8) +
  geom_vline(xintercept = 0, linetype = "dashed", color = "grey40", linewidth =
0.5) +
  scale_color_manual(
    values = c("p < 0.05" = "#2E5090", "No significativo" = "#AAAAAA"),
    name = ""
  ) +
  facet_grid(grupo ~ dependiente, scales = "free_x", space = "free_y") +
  labs(title = NULL, subtitle = NULL, x = "Coeficiente estimado", y = "") +
  theme_minimal(base_size = 10) +
  theme(
    legend.position = "bottom",
    plot.title = element_text(face = "bold", size = 11),
    plot.subtitle = element_text(size = 9, color = "grey40"),
    strip.text = element_text(face = "bold", size = 9),
    strip.background = element_rect(fill = "#EEF2F7", color = NA),
    panel.spacing = unit(0.5, "lines")
  )

ggsave(paste0(ruta_datos, "grafico2_forest_completo.png"),
       g_forest, width = 16, height = 8, dpi = 300)

```

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Pablo Martín Huidobro, estudiante de Doble Grado en Business Analytics y Relaciones internacionales de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " El uso de la IA en el lugar de trabajo: datos de la Encuesta Europea sobre las Condiciones de Trabajo 2024 ", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
3. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
4. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
5. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
6. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 15/06/2026

Firma:

