

CAMBIO TECNOLÓGICO, ESTRUCTURA OCUPACIONAL Y DESIGUALDAD DE GÉNERO EN ESPAÑA

Raquel Sebastian

UCM, ICAE y EQUALITAS

Resumen

Este artículo examina cómo el cambio tecnológico ha reconfigurado la estructura ocupacional en España y cómo este proceso afecta a la desigualdad salarial en general, y a la brecha de género en particular. En la primera parte, tras medir y caracterizar el cambio ocupacional por percentiles salariales —con especial atención a la dimensión de género—, mostramos que el patrón de empleo varía desde una fase compatible con la RBTC hacia una etapa reciente de mejoramiento progresivo, encontrando trayectorias diferenciadas para mujeres y hombres. En la segunda parte, se muestran los efectos de la automatización de la IA sobre la distribución salarial completa mediante el uso de distribuciones contrafactuales. Los resultados indican que la automatización aumenta la desigualdad agregada, pero reduce la brecha salarial de género, mientras que la IA incrementa la desigualdad y presenta efectos mixtos sobre el género según la métrica utilizada. El hilo conductor teórico es la composición de tareas: qué se automatiza, qué se complementa y cómo se reasignan trabajadores a lo largo de la distribución salarial.

Palabras clave: cambio tecnológico, estructura ocupacional, desigualdad salarial, brecha de género.

Abstract

This article examines how technological change has reshaped the occupational structure in Spain and how this process affects wage inequality in general, and the gender pay gap in particular. In the first part, after measuring and characterizing occupational change by wage percentiles—with special attention to the gender dimension—we show that the employment pattern shifts from a phase consistent with the U-shaped curve toward a recent stage of progressive improvement, revealing distinct trajectories for women and men. In the second part, we demonstrate the effects of automation and AI on the overall wage distribution using counterfactual distributions, finding that automation increases aggregate inequality but reduces the gender wage gap, while AI increases inequality and shows mixed effects on gender depending on the metric used. The theoretical thread is task composition: what is automated, what is complemented, and how workers are reallocated across the wage distribution.

Keywords: technological change, occupational structure, wage inequality, gender gap.

JEL classification: J24, J31, O33.

I. INTRODUCCIÓN

La automatización, robotización e inteligencia artificial (IA) crecen a un ritmo exponencial, imponiendo un cambio de paradigma en la forma de entender el factor trabajo y acelerando la llamada Cuarta Revolución Industrial. Estas tecnologías, capaces de tomar decisiones y operar de forma autónoma, no solo permiten la creación

de nuevos puestos de trabajo y complementar muchos ya existentes, sino también la sustitución parcial o total de ocupaciones cuyo desempeño es repetitivo o rutinario. Si bien el cambio tecnológico ha sido históricamente el motor fundamental del progreso económico y la mejora de los niveles de vida (Frey, 2019), su efecto distributivo sobre el empleo y la desigualdad salarial sigue siendo objeto de un intenso debate (Graetz y Michaels, 2018). Comprender

cómo estos avances reconfiguran la distribución de los ingresos es esencial para la cohesión social y la estabilidad, especialmente en economías con alta segmentación laboral como la española.

Desde finales de los años noventa, la literatura documentó el fenómeno de la polarización ocupacional –crecimiento simultáneo del empleo en los extremos de la distribución salarial, a expensas del segmento intermedio– como el principal efecto de la automatización sobre el mercado laboral (Autor *et al.*, 2006; Goos y Manning, 2007; Autor y Dorn, 2013). Este patrón se explica bajo la hipótesis del “cambio tecnológico sesgado hacia las rutinas” (RBTC, en inglés), que define que la tecnología sustituye tareas rutinarias y codificables, concentradas típicamente en ocupaciones de cualificación media (Spitz-Oener, 2006). En el contexto español, esta secuencia ha sido documentada: una primera etapa compatible con la polarización, que da paso en el período más reciente a indicios de un mejoramiento progresivo en la parte alta de la distribución (Sebastian, 2018 y 2025).

Este artículo propone una lectura integrada de estos procesos con un foco crucial en la dimensión de género. La premisa fundamental es que el efecto de las nuevas tecnologías no es sobre las ocupaciones directamente, sino sobre las tareas que componen dichas ocupaciones. La reasignación de tareas, sesgada por su posible automatización o complementariedad con las nuevas herramientas (IA), altera la forma de la estructura ocupacional y, de manera intermediada, la desigualdad en la distribución de los ingresos laborales. El énfasis en el género de los trabajadores es crucial, ya que la segregación ocupacional implica que mujeres y hombres presenten tareas muy diferenciadas, lo que se traduce en trayectorias laborales divergentes y distinta exposición a la automatización y la IA (Sebastian, 2023).

El trabajo se estructura en dos partes. En una primera sección, se mide y caracteriza el cambio ocupacional documentando su dimensión de género a partir de un marco de medición que ordena las ocupaciones por su salario medio y observa cómo varía su peso relativo por percentiles (0-100). La fotografía que emerge para el período 1994-2024

es de convergencia en la participación laboral por sexo, pero con ajustes diferenciados: el impacto de la automatización recae con mayor intensidad sobre ocupaciones masculinizadas más abundantes en el tramo intermedio, mientras que las mujeres ganan peso en servicios y profesiones, mostrando avances en la cola alta de la distribución.

En la segunda parte, se traslada ese diagnóstico al terreno distributivo, respondiendo a dos preguntas: qué parte del aumento de la desigualdad salarial puede atribuirse a la tecnología y cómo incide en la brecha de género. Partiendo del marco de análisis de Palomino *et al.* (2025), que aísla los efectos causales de la automatización y de la IA sobre la distribución salarial completa a partir de distribuciones contrafactuales, se documenta el impacto tecnológico por grupos (sexo, edad, educación) mediante instrumentos tipo Bartik (*shift-share*) y métricas de IA complementarias. La comparación entre la distribución observada y la distribución contrafactual, medida por índices de desigualdad como el de Gini, la desviación media en logaritmos (*MLD*) y diferentes cuotas salariales, permite aislar el efecto del componente tecnológico. Los hallazgos confirman que la automatización ha sido el principal motor de la desigualdad agregada a lo largo del período 2000-2019, si bien con un efecto reductor sobre la brecha salarial de género, mientras que la IA ha incrementado la desigualdad total (Palomino *et al.*, 2025).

La contribución del artículo es doble. En el plano descriptivo, aporta una cronología clara y desagregada por sexo del cambio ocupacional en España, describiendo quién gana y quién pierde en cada etapa. En el plano causal, enlaza ese cambio ocupacional con unos resultados empíricos que cuantifican el papel de la tecnología sobre la desigualdad y la brecha de género, considerando automatización e IA como causas distintas. El resto del trabajo se organiza así: la sección segunda presenta el marco conceptual de tareas y documenta los patrones de cambio ocupacional y su dimensión de género. La tercera sección expone el método seguido en Palomino *et al.* (2025) para identificar el componente tecnológico y revisa su incidencia sobre la desigualdad y la brecha salarial. La última sección presenta las conclusiones y posibles medidas de política económica.

II. CAMBIO OCUPACIONAL, TAREAS Y GÉNERO

1. Marco conceptual: de SBTC a RBTC

El aumento de la desigualdad salarial en España durante la última década y media no puede atribuirse únicamente a los vaivenes del ciclo ni a los efectos inmediatos de la Gran Recesión (Sebastian, 2022). Aunque la crisis y la recuperación posterior explican parte del deterioro en los tramos bajos de la distribución, existen factores estructurales —en particular, la trayectoria del cambio tecnológico— que han reconfigurado la demanda de trabajo (Rodríguez y Sebastian, 2023). La inquietud por el impacto del progreso tecnológico sobre el empleo y la desigualdad es antigua: ya Keynes (1930) advertía sobre sus implicaciones en *Posibilidades económicas para nuestros nietos*. Esa preocupación se ha reavivado con la automatización y la digitalización recientes (Mokyr et al., 2015).

Históricamente, las sucesivas oleadas tecnológicas han alterado la organización del trabajo y la composición sectorial. La mecanización inicial sustituyó a artesanos por trabajadores menos cualificados; más tarde, desde la segunda Revolución Industrial hasta finales del siglo XX, la difusión de las tecnologías de la información y la comunicación (TIC) elevó la productividad relativa del trabajo cualificado y su demanda, impulsando ocupaciones directivas y profesionales en detrimento de puestos de producción. Este patrón, conocido como cambio tecnológico sesgado hacia los trabajadores cualificados (*Skill-biased technical change*, SBTC), predice una relación creciente entre cualificación y empleo (Tinbergen, 1974).

A partir de los 2000, esa relación lineal se debilita y emerge un perfil en forma de U: el empleo crece en los extremos —puestos menos y más cualificados— mientras retrocede en el centro de la distribución salarial. Este proceso de polarización se documenta en diversos contextos (Wright y Dwyer, 2003; Autor et al., 2003; Goos y Manning, 2007; Acemoglu y Autor, 2011) y, para explicarlo, la literatura reorienta el foco desde el nivel educativo hacia la naturaleza de las tareas. La hipótesis del cambio tecnológico sesgado hacia la rutina (*Routine-biased technical change*, RBTC) sostiene

que la automatización sustituye con mayor facilidad las tareas repetitivas y estandarizables —abundantes en ocupaciones de cualificación media—, mientras que las tareas abstractas (problema-solución, creatividad, gestión), típicas de la parte alta, son complementadas por la tecnología, y muchas tareas manuales no codificables, más frecuentes en la parte baja, resisten la sustitución directa (Autor et al., 2003; Goos y Manning, 2007; Biagi y Sebastian, 2020).

Desde esta perspectiva de tareas, la polarización se interpreta como una reasignación del empleo lejos de actividades rutinarias hacia polos manuales no rutinarios y abstractos. Ello tiene consecuencias sobre la estructura ocupacional y la distribución del ingreso: se reducen los puestos intermedios y se expanden los extremos. No obstante, una cosa es el aumento de la polarización y otra muy distinta es constatar que este aumento de la polarización provoca un aumento en la desigualdad. Es importante darse cuenta de que la tecnología interactúa con instituciones laborales, la educación, el nivel de competencia, los cambios sectoriales y las políticas públicas, por lo que su contribución al aumento de las brechas de ingresos, aunque relevante, no es por sí sola concluyente (Acemoglu y Autor, 2011; Mokyr et al., 2015).

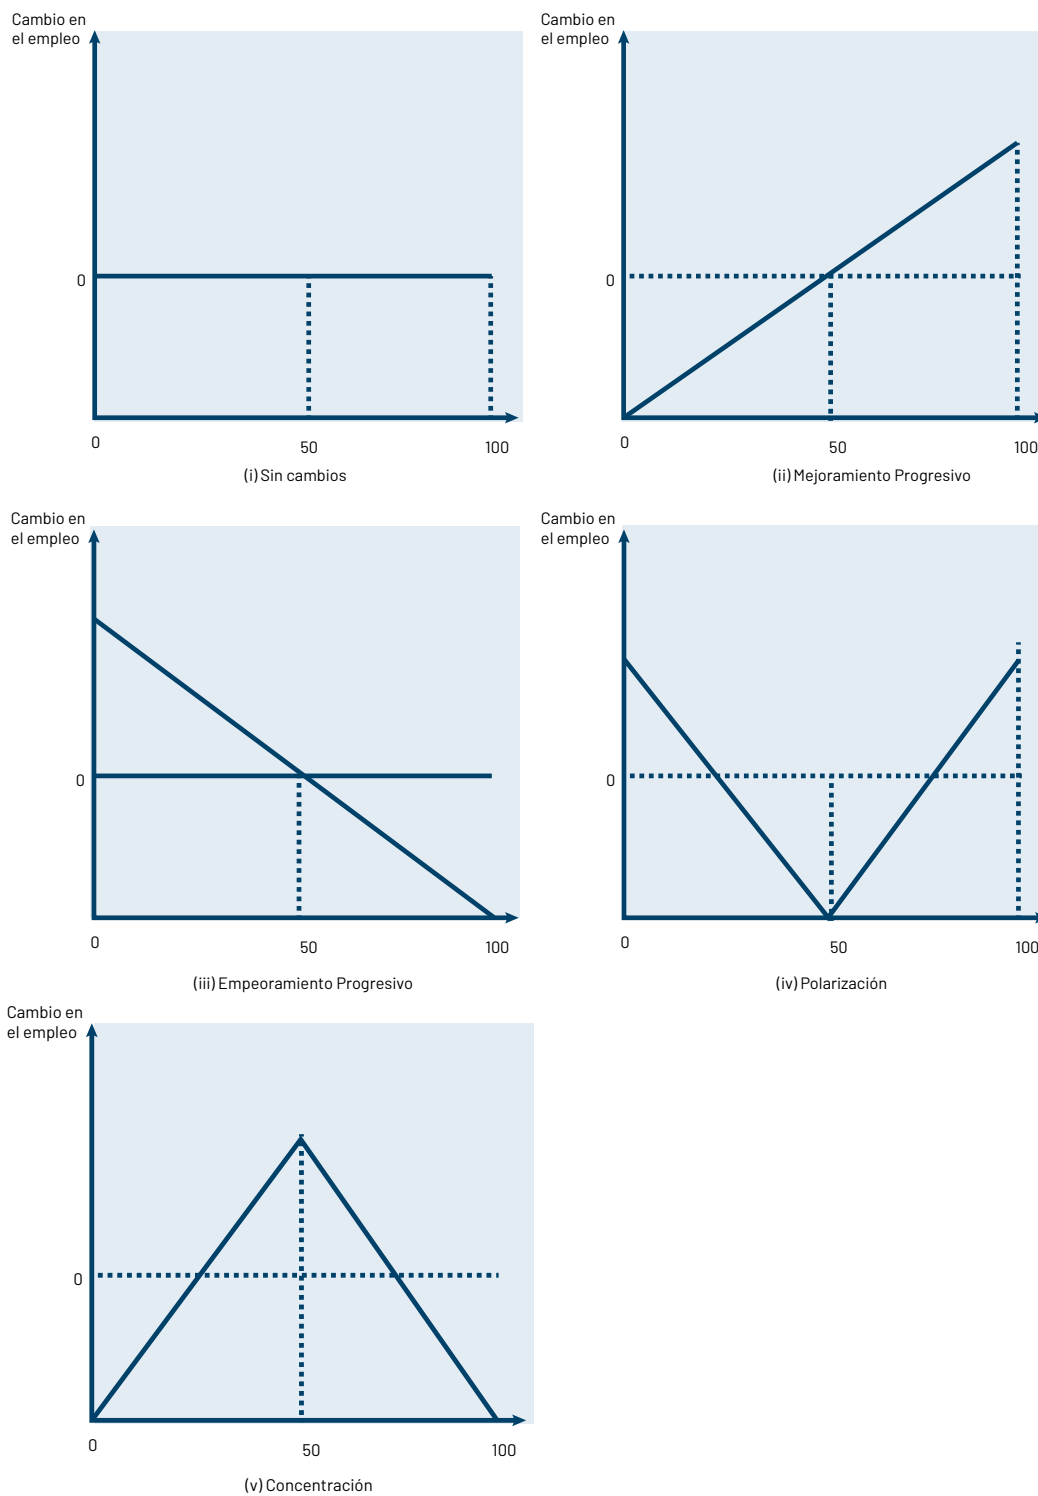
2. Medición

En síntesis, pueden distinguirse cinco formas de cambio ocupacional. Para evaluar cómo la automatización afecta al empleo, se identifica en qué tramos de la escala salarial (bajo, medio y alto) se crean y en cuáles se destruyen puestos de trabajo. Tomando el salario medio de cada ocupación como aproximación a su “calidad”, se ordenan las ocupaciones de menor a mayor salario y, para cada una de ellas, se calcula la variación porcentual del empleo entre dos períodos suficientemente alejados en el tiempo.

Para visualizar dónde se concentran las ganancias y pérdidas dentro de la distribución salarial, las ocupaciones se agrupan por percentiles (0–100): el 0 corresponde a la ocupación con menor salario medio y el 100 a la de mayor salario. Esta representación facilita una lectura inmediata del impacto de la automatización en el mercado de trabajo.

GRÁFICO 1

DISTRIBUCIÓN DE LOS CAMBIOS EN EL PORCENTAJE DE EMPLEO



Fuente: Rodríguez et al. (2025).

A título ilustrativo, Rodríguez *et al.* (2025) distinguen cinco trayectorias posibles de cambio ocupacional. La primera describe estabilidad total de las cuotas de empleo (panel a del gráfico 1), es decir, ausencia de polarización. La segunda es el “mejoramiento progresivo” (panel b): las ocupaciones de mayor cualificación —y salarios más altos— ganan peso en el empleo total, coherente con la hipótesis del cambio tecnológico sesgado hacia los cualificados (SBTC). La tercera, “empeoramiento progresivo” (panel c), muestra lo contrario: crecen las ocupaciones de baja cualificación y retroceden las de alta cualificación. La cuarta es la “polarización del empleo” (panel d), ampliamente documentada por Wright y Dwyer (2003), Goos y Manning (2007), Goos *et al.* (2014) y Sebastian (2018): cae el peso de las ocupaciones medias en favor de los extremos, bajo y alto, en línea con el cambio tecnológico sesgado hacia la rutina (RBTC). Por último, la “concentración del empleo” (panel e): las ocupaciones de nivel medio ganan terreno frente a las de los extremos; es, en esencia, el reverso de la polarización, al concentrarse el empleo en el segmento central.

3. Resultados por décadas

El gráfico 2 muestra la evolución de la estructura ocupacional en España a lo largo del período 1994–2024. En el eje horizontal se sitúan las ocupaciones ordenadas por su salario medio y representadas por percentiles (0–100), de modo que los valores cercanos a 0 agrupan las ocupaciones peor remuneradas y los cercanos a 100, las de mayor salario. El eje vertical recoge la variación porcentual del empleo por ocupación entre períodos, lo que permite identificar, de forma sintética, dónde se concentran los avances y retrocesos del empleo dentro de la distribución salarial. Esta lectura facilita distinguir no solo cambios en el nivel agregado, sino también desplazamientos en la composición del empleo entre ocupaciones de distinta cualificación.

En el período 1994–2004 se observa un patrón nítido de polarización: crecen las participaciones en los extremos de la distribución —ocupaciones de salarios bajos y altos—, mientras que el segmento intermedio pierde terreno. Este comportamiento es coherente con la evidencia disponible para

España, que documenta un desplazamiento desde ocupaciones de cualificación media hacia actividades situadas en la base y en la cúspide de la escala salarial (Anghel *et al.*, 2014; Sebastian, 2018). Desde una perspectiva analítica, la década se caracteriza por la expansión simultánea de servicios de baja remuneración y de perfiles profesionales avanzados, con un estancamiento relativo de los puestos de corte rutinario y medio.

Durante 2004–2014, esta dinámica se intensifica, con una contracción más pronunciada del empleo en las ocupaciones de nivel medio. La crisis financiera de 2008 actúa como catalizador de las tendencias previas, acelerando la destrucción de puestos en actividades intensivas en tareas rutinarias. La literatura subraya el papel de la automatización y la difusión de tecnologías que sustituyen dichas tareas, especialmente en el corazón de la distribución salarial (Sebastian, 2018; Rodríguez y Sebastian, 2022). El resultado es una recolocación del empleo que ahonda la brecha entre los extremos y reduce aún más el peso relativo del centro de la distribución salarial.

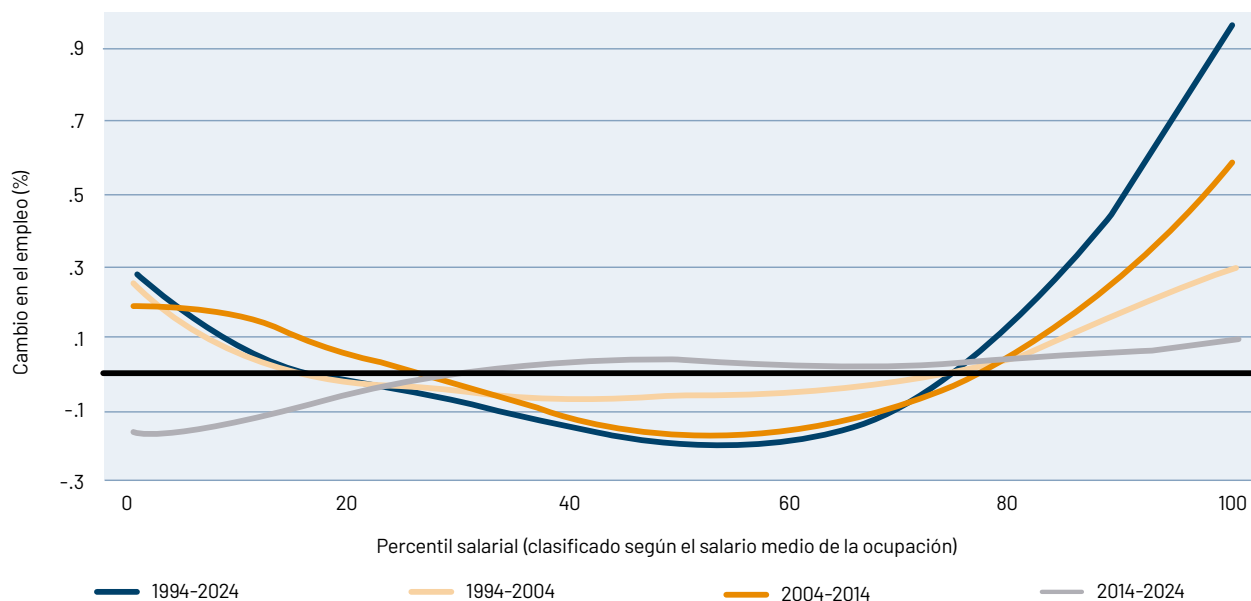
En la última década (2014–2024) se aprecia un cambio de perfil hacia un mejoramiento progresivo: las pérdidas de empleo se concentran en los percentiles inferiores, mientras que el crecimiento se desplaza hacia los percentiles superiores. Este patrón es consistente con la expansión reciente de la IA y de tecnologías complementarias a las habilidades cognitivas y analíticas, que habrían impulsado la demanda de ocupaciones de mayor cualificación sin erosionar de manera marcada el empleo intermedio. Resultados afines se encuentran en trabajos recientes para otros contextos, que apuntan a una recomposición del empleo a favor de segmentos altamente cualificados en la fase más reciente del cambio tecnológico (Acemoglu, 2025; Acemoglu y Johnson, 2024; Acemoglu y Restrepo, 2020; Albanesi *et al.*, 2025).

Tomado en conjunto, el período 1994–2024 muestra una tendencia neta hacia la polarización del empleo: aumentos en los extremos de la distribución —especialmente a partir del percentil 80— y retrocesos en el tramo medio (aproximadamente percentiles 20–80). Además, el avance ha sido más

GRÁFICO 2

CAMBIO OCUPACIONAL EN TÉRMINOS RELATIVOS ENTRE 1994-2024

En porcentaje



Fuentes: Elaboración propia a partir de los datos a medida de la Encuesta de población activa (1994, 2004, 2014 y 2024), la EPF (1990) y la EU-SILC (Estadísticas de la Unión Europea sobre ingresos y condiciones de vida) desde el 2004 hasta el 2019.

intenso en la parte alta de la distribución salarial que en la baja, lo que sugiere que la recuperación y el crecimiento más recientes han favorecido, en mayor medida, a las ocupaciones de mayor cualificación y mejor remuneración. Esta lectura, apoyada en el gráfico 2, permite entender no solo la dirección del cambio, sino también su localización dentro de la estructura ocupacional.

4. Dimensión de género

A continuación, se pasa de la visión agregada del cambio ocupacional a su descomposición por género. Como punto de partida, el cuadro n.º 1 compara la distribución de hombres y mujeres por ocupación al inicio y al cierre del período 1994-2024. El rasgo más llamativo es la fuerte convergencia en la participación laboral entre ambos colectivos: la brecha, que en 1994 rondaba los 20 puntos porcentuales (p. p.), desciende hasta aproximadamente 7 p. p. en 2024.

Esta aproximación entre sexos también se aprecia al clasificar las ocupaciones por nivel salarial. En el tramo de menor remuneración, la presencia femenina pasa a situarse por encima de la masculina en 2024; en el segmento medio, la distancia se reduce en torno a 10 p. p.; y en la parte alta de la distribución, la ventaja masculina se limita a unos 2 p. p.

Si ponemos el foco en las ocupaciones concretas, se observa que los hombres aumentan su peso únicamente en Servicios y ventas (ISCO-08, grupo 5, +1,72 p. p.), Técnicos y profesionales de apoyo (ISCO-08, grupo 3, +3,53 p. p.) y Profesionales (ISCO-08, grupo 2, +2,90 p. p.). Por el contrario, entre las mujeres solo se registra un descenso significativo —superior a un punto porcentual— en Directivos (ISCO-08, grupo 1, -1,34 p. p.). Estos patrones sirven de base para el análisis de la polarización laboral con perspectiva de género que desarrollamos a continuación.

CUADRO N. 01

PARTICIPACIÓN LABORAL DE HOMBRES Y MUJERES POR OCUPACIÓN (1994-2024)

NIVEL SALARIAL	OCUPACIÓN	HOMBRES			MUJERES		
		EMPLEO 1994	EMPLEO 2024	VARIACIÓN	EMPLEO 1994	EMPLEO 2024	VARIACIÓN
Bajo	Ocupaciones elementales	7,87	4,97	-2,91	5,08	5,42	0,34
	Agricultura, silvicultura y pesca	6,03	2,24	-3,78	1,36	0,51	-0,85
	Servicios y venta	6,86	8,58	1,72	5,84	11,85	6,01
	Total	20,77	15,79	-4,97	12,28	17,77	5,49
Medio	Artesanos y operarios de oficios	17,32	10,23	-7,09	1,55	1,04	-0,51
	Operadores y ensambladores	9,98	7,60	-2,38	1,41	1,15	-0,25
	Apoyo administrativo	5,24	3,26	-1,97	5,59	6,31	0,72
	Total	32,54	21,10	-11,45	8,55	8,50	-0,04
Alto	Técnicos y profesionales de apoyo	4,58	8,11	3,53	2,11	4,65	2,54
	Profesionales	5,35	8,25	2,90	4,14	10,69	6,55
	Directivos	6,65	3,44	-3,21	3,03	1,69	-1,34
	Total	16,59	19,80	3,22	9,28	17,03	7,76

Fuentes: Elaboración propia a partir de los datos a medida de la Encuesta de población activa (1994 y 2024) y la EU-SILC (Estadísticas de la Unión Europea sobre ingresos y condiciones de vida) desde el 2004 hasta el 2019.

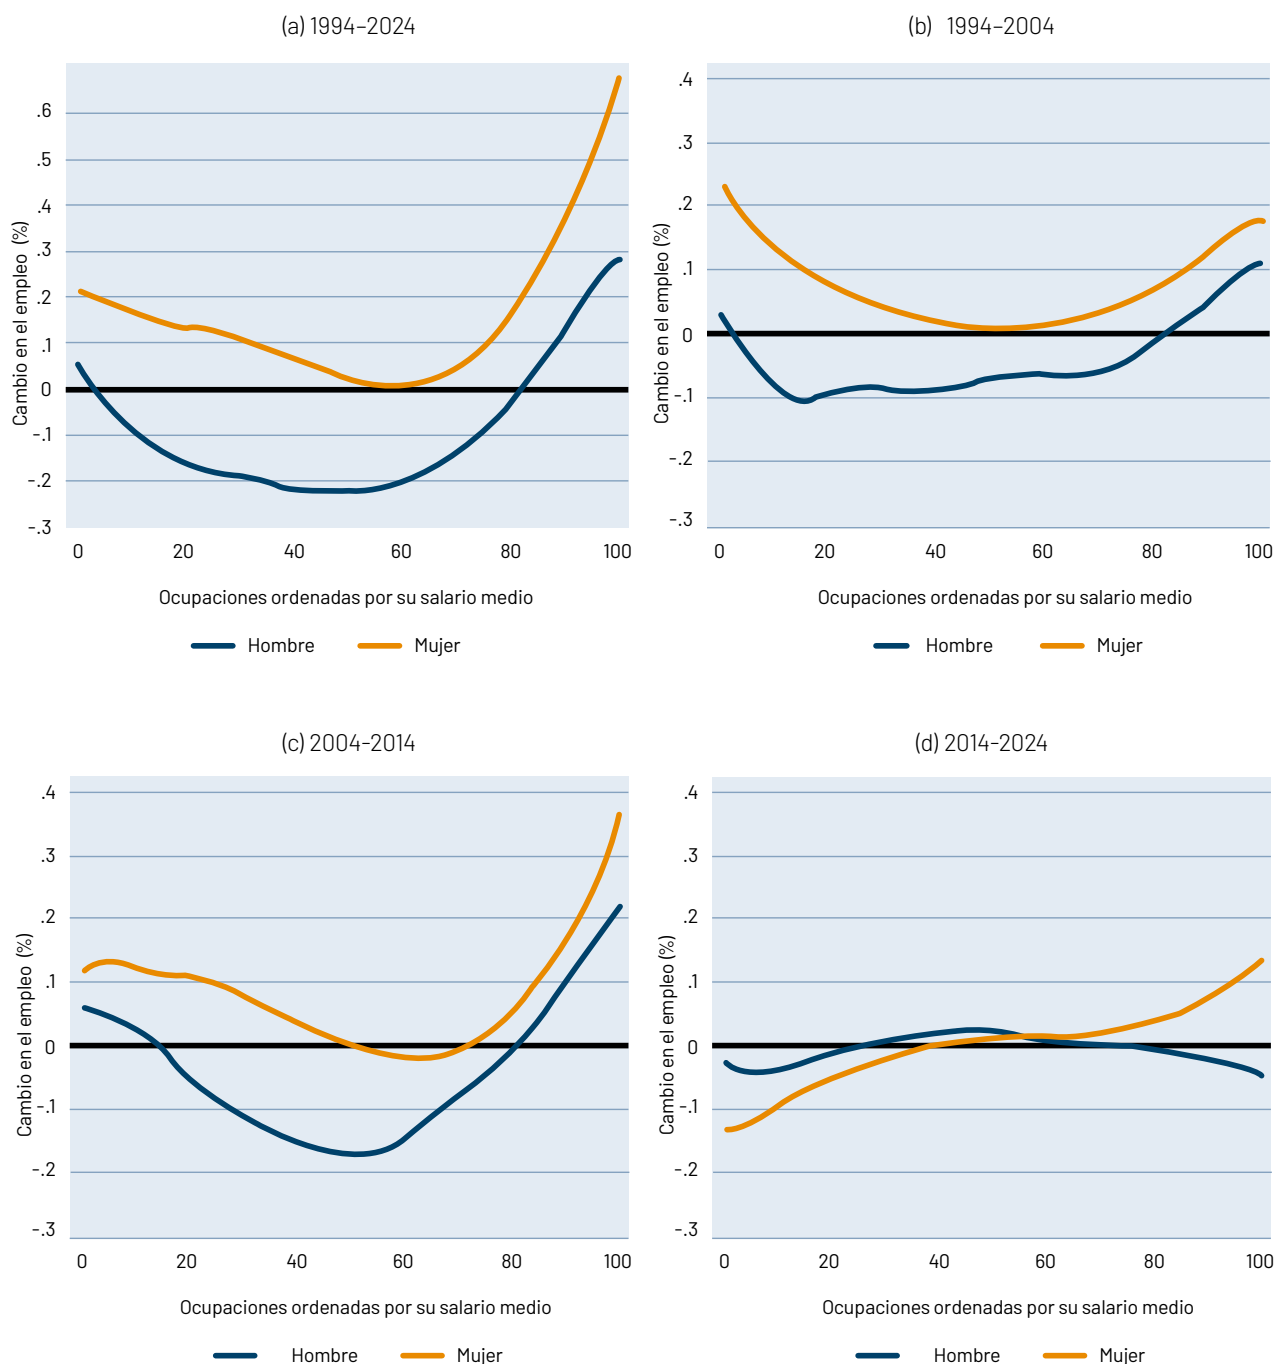
En línea con lo mostrado previamente, el gráfico 3 (paneles a, b, c y d) evidencia que la trayectoria del empleo ha sido muy distinta para hombres y mujeres, en sintonía con Sebastian (2023). Para todo el período 1994-2024, el empleo femenino crece en prácticamente todos los puntos de la distribución salarial, con la única excepción del entorno del percentil 60, donde se mantiene estable. En contraste, la contracción total del empleo asociada a la automatización recae sobre los hombres: solo en los extremos de la distribución salarial se aprecia un ligero avance masculino. Además, el perfil femenino presenta un patrón de polarización, similar al documentado por Cerina et al. (2021) para Estados Unidos en las últimas tres décadas.

Por décadas, emergen matices. Entre 1994 y 2004, el empleo femenino aumenta en todas las ocupaciones, mientras que el masculino solo mejora en las posiciones de mayor salario medio. En 2004-2014, las mujeres registran avances en el tramo inferior de la distribución y también por encima del percentil 80, al tiempo que los hombres apenas ganan peso en las ocupaciones mejor remuneradas y en el extremo inferior (por debajo del percentil 10). En 2014-2024, el patrón femenino se reconfigura: el crecimiento se concentra en la parte alta y se destruye empleo en la baja. Para los hombres, la evolución es más contenida, con un leve incremento en los percentiles medios y sin variaciones relevantes en los extremos. En conjunto, esta última etapa su-

GRÁFICO 3

CAMBIO OCUPACIONAL POR GÉNERO EN TÉRMINOS RELATIVOS ENTRE 1994-2024

En porcentaje



Fuentes: Elaboración propia a partir de los datos a medida de la Encuesta de población activa (1994 y 2024) y la EU-SILC (Estadísticas de la Unión Europea sobre ingresos y condiciones de vida) desde el 2004 hasta el 2019.

giere un ajuste más acotado, con menor dispersión del impacto por género y nivel salarial.

Analizar el cambio ocupacional por género es clave para entender quién gana y quién pierde con cada ola tecnológica y, en consecuencia, diseñar políticas eficaces y justas. La reasignación de tareas y puestos no afecta por igual a mujeres y hombres debido a la segregación sectorial y ocupacional, a la distinta exposición a tareas rutinarias o abstractas y a brechas persistentes en el acceso a formación, puestos directivos y redes profesionales. Sin esta lente, pueden invisibilizarse pérdidas concentradas en ocupaciones “feminizadas” o “masculinizadas”, así como oportunidades de ascenso en los tramos altos de la distribución salarial. Incorporar la perspectiva de género permite orientar la recualificación y la mejora de competencias hacia colectivos concretos, adaptar horarios y sistemas de cuidados para favorecer la participación y corregir sesgos en la adopción de tecnologías (incluida la IA) que podrían amplificar desigualdades existentes. En suma, leer la transformación del empleo con enfoque de género no es un añadido descriptivo: es una condición para anticipar impactos, cerrar brechas y asegurar que los beneficios del cambio tecnológico se repartan de forma equitativa.

El diagnóstico ocupacional por percentiles salariales y su descomposición por género permiten ubicar dónde se reordenan las posiciones en el mercado de trabajo y quiénes protagonizan esos movimientos. El siguiente paso es traducir ese mapa de desplazamientos en cambios sobre la distribución de salarios: no solo cuánto varía la dispersión total, sino también cómo se modifica la brecha entre mujeres y hombres cuando aislamos la contribución de las nuevas tecnologías. Con este objetivo, la sección tercera aplica un enfoque contrafactual que identifica la parte de la desigualdad atribuible a la automatización de la IA y evalúa sus efectos diferenciados por género.

III. TECNOLOGÍA, DESIGUALDAD Y GÉNERO

La sección segunda mostró que la reconfiguración del empleo en España responde a una polarización impulsada por el cambio tecnológico, con

patrones diferenciados por género. La existencia de esta polarización plantea la pregunta de si la tecnología ha contribuido al aumento de la desigualdad salarial, un fenómeno que, para el caso español, solo ha sido cuantificado de forma causal por un estudio (Palomino *et al.*, 2025). Por ello, esta sección revisa los resultados clave de dicho trabajo, centrándose en cómo la automatización (sustitución de tareas rutinarias) y la inteligencia artificial (complementación de tareas abstractas) impactan en la desigualdad total y en la brecha salarial de género, descomponiendo los efectos por grupos demográficos.

1. Marco empírico y efecto agregado de la tecnología

El análisis realizado se fundamenta en la teoría de tareas: las ocupaciones son conjuntos de tareas rutinarias, manuales y abstractas. El cambio tecnológico sustituye tareas codificables (automatización) y complementa (supuestamente) capacidades no rutinarias (IA), lo que impulsa la polarización del empleo y, potencialmente, de los salarios. El reto empírico consiste en medir de forma precisa la exposición tecnológica de cada grupo demográfico y trasladar este efecto micro a indicadores de desigualdad agregada, un problema abordado por Palomino *et al.* (2025) a través de un marco causal y contrafactual.

La identificación empírica se lleva a cabo en dos etapas:

1. *Estimación causal de crecimiento salarial.* Se estima el efecto causal de la exposición tecnológica sobre el crecimiento salarial promedio de grupos definidos por sexo, edad, nivel educativo y región. Para abordar la endogeneidad de las variables tecnológicas, se utiliza una estrategia de variables instrumentales (VI) tipo *shift-share* (Bartik). Este instrumento combina la estructura ocupacional inicial del grupo con *shocks* tecnológicos exógenos y externos (como el precio de los robots o la difusión global de la IA), lo que garantiza que los coeficientes tecnológicos estimados puedan interpretarse como efectos causales sobre el salario de cada grupo. Además, se aplican test de robustez, entre ellos un análisis de sensibilidad tipo *bounding* respecto al sesgo por variables omitidas.

2. *Construcción de distribuciones contrafactuales.* Los coeficientes tecnológicos de la regresión obtenidos en el primer paso se utilizan para construir una distribución de salarios "sin tecnología" para el período de estudio (2000–2019). Esta distribución contrafactual se compara con la distribución salarial observada utilizando métricas estándar (tales como el índice de Gini, el *MLD*, y cuotas salariales por tramos: 10 por 100 más alto, 50 por 100 más bajo, etc.). Si el índice de desigualdad en la distribución contrafactual es inferior al observado, se concluye que la tecnología ha contribuido a aumentar la desigualdad.

Métricas de exposición tecnológica

- *Automatización.* Se emplea una medida dinámica de rutina por ocupación denominada *RTI un-fixed* (RSH-UF, en adelante). Este índice captura la diferencia entre la intensidad de tareas rutinarias y abstractas para cada período considerado, y posteriormente se agrega por grupos demográficos utilizando para ello los pesos demográficos correspondientes. A diferencia de los índices clásicos empleados en la literatura (véase, por ejemplo, Autor y Dorn, 2013) que son estáticos, el índice RSH-UF incorpora los cambios en la composición del empleo entre ocupaciones y la evolución de la rutinización dentro de las ocupaciones a lo largo del tiempo.
- *Inteligencia artificial (IA).* Palomino *et al.* (2025) utilizan tres indicadores complementarios que recogen el potencial de la IA para incidir en las habilidades ocupacionales: i) el índice de Felten *et al.* (2018), que vincula el progreso de aplicaciones de IA con las habilidades ocupacionales; ii) el índice de Webb (2020), basado en la superposición textual entre patentes de IA/robots y las descripciones de tareas de la base de datos O*NET; y iii) la idoneidad para el aprendizaje automático (SML, *suitability for machine learning*) propuesto por Brynjolfsson *et al.* (2018), el cual evalúa el potencial transformador del *machine learning* sobre actividades concretas.

Es relevante destacar que todas las medidas de exposición tecnológica mencionadas se construyen a partir de fuentes de tareas y capacidades

desarrolladas para Estados Unidos (O*NET, patentes), lo que refuerza la validez de la estrategia de identificación al comparar tareas, puesto que la exposición no va a estar endógenamente determinada por la evolución de los salarios en España.

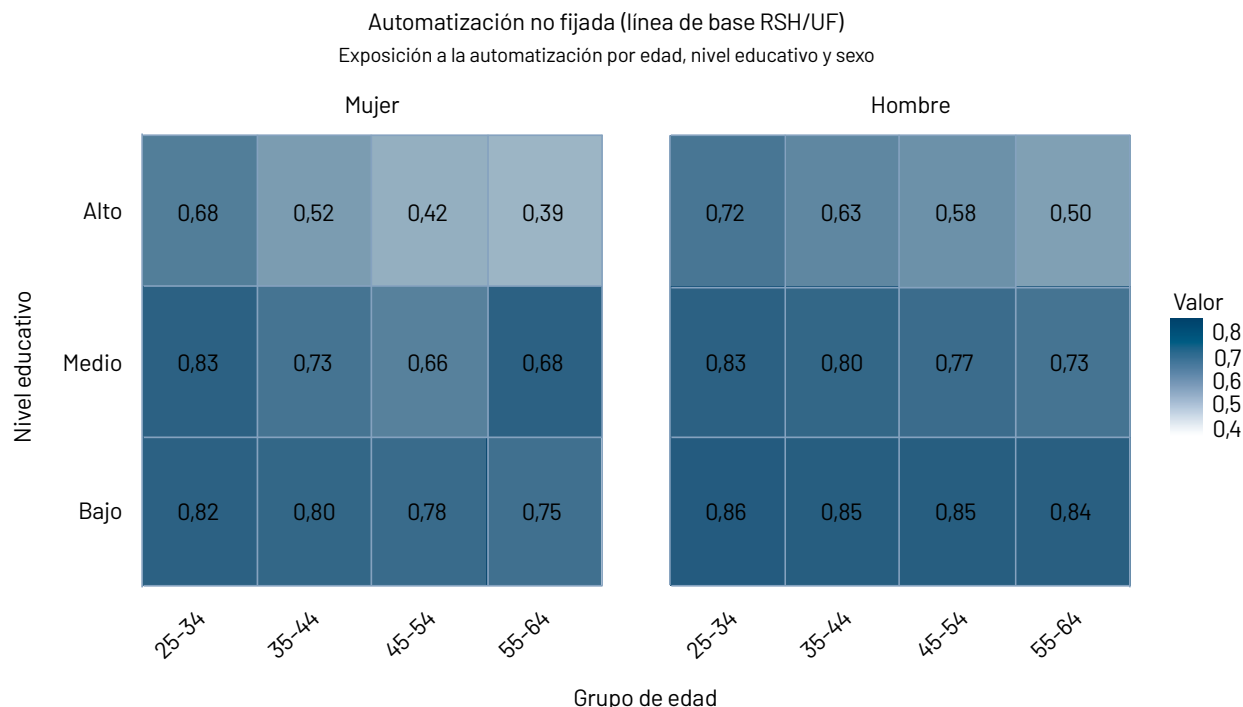
2. Brecha salarial de género: resultados e interpretación

Una vez cuantificado el efecto agregado, el interés pasa de ser cuánto cambia la desigualdad a quiénes experimentan los cambios y por qué. El enfoque contrafactual de Palomino *et al.* (2025) permite medir la contribución de la tecnología a la brecha salarial de género mediante la comparación entre la distribución observada y una distribución "sin tecnología". La brecha se define como la diferencia de salarios medios entre hombres y mujeres; el indicador central es la variación relativa de esa brecha en la distribución contrafactual respecto a la observada: valores positivos implican que, sin tecnología, la brecha sería mayor y, por tanto, que la tecnología la ha reducido; valores negativos implican lo contrario. Esta misma lógica se aplica a la prima educativa, garantizando consistencia entre el análisis por grupos y los agregados distributivos.

El resultado central a largo plazo es que la automatización, medida con el índice dinámico RSH-UF, se asocia a una reducción de la brecha de género: en ausencia de ese canal, la brecha sería sustancialmente mayor. La explicación se basa en la composición de la fuerza laboral. Para el índice de exposición a la automatización RSH-UF, los hombres aparecen sistemáticamente más expuestos dentro de cada nivel educativo, frente a medidas clásicas de exposición a la automatización para las cuales las diferencias por sexo son menores e incluso se invierten para el grupo de baja educación. Es decir, para el índice que mejor capta la evolución de las tareas rutinarias aquellas ocupaciones más masculinizadas son las más expuestas a la automatización y, por este motivo, el diferencial o brecha salarial media entre hombres y mujeres se reduce cuando el componente tecnológico se excluye del salario.

En cuanto a la IA, los efectos por género no son unívocos y dependen de la métrica de exposición utilizada. Para el índice de Felten, que vincula los

GRÁFICO 4
EXPOSICIÓN A LA AUTOMATIZACIÓN POR GRUPOS DEMOGRÁFICOS (ÍNDICE RSH-UF)



Fuente: Palomino et al. (2025).

avances de la IA con las habilidades ocupacionales, se obtiene una reducción de la brecha salarial; por el contrario, para el índice de Webb— basado en el solapamiento entre patentes y los descriptores de tareas— y el índice SML —que mide la capacidad para que se dé aprendizaje automático mediante machine learning— se observa un ensanchamiento de la brecha de género. Esta divergencia es, después de todo, esperable dado que cada índice captura facetas distintas de la IA y, por tanto, cada índice de exposición a la IA recoge aspectos de la relación entre las composiciones ocupacionales y el género distintos. Por otro lado, la adopción de la IA en España entre los años 2015–2019 es reciente y aún está sesgada hacia ocupaciones de alta cualificación, donde la representación relativa de mujeres y hombres varía por rama y perfil.

Dicho todo esto, conviene interpretar los resultados anteriores junto a la evidencia descriptiva anterior. En el año 2000, la relación “en bruto” entre

exposición y salario ya mostraba gradientes de signo opuesto para la automatización e IA: los grupos más expuestos a la automatización presentaban salarios medios más bajos, mientras que para los índices de Felten y Webb la exposición a la IA se concentraba en los grupos salariales altos. Ese patrón de partida condiciona cómo la tecnología afecta a la brecha salarial: si la automatización incide más en ocupaciones masculinizadas de cualificación media, reducirá la brecha; si por el contrario, la IA recompensa las tareas y ocupaciones propias de la parte alta de la distribución salarial, el efecto sobre la brecha dependerá de la composición de género de este tramo.

3. Mecanismo y heterogeneidades: sexo, edad y educación

Para entender mejor cómo funciona el mecanismo detrás de las brechas, resulta útil partir de la distribución inicial de la exposición por sexo y educación.

El gráfico 4, para el año 2000 y el índice RSH-UF, muestra que en cada nivel educativo los hombres presentan mayor exposición media a la automatización que las mujeres. Este patrón es consistente con la segregación ocupacional descrita en la sección segunda: las tareas rutinarias más susceptibles de sustitución se concentran en ocupaciones masculinizadas de cualificación intermedia (industria y ciertos servicios técnicos). Cuando se repite el ejercicio con la medida clásica de exposición a la automatización (Autor y Dorn, 2013), la diferencia por sexo se reduce e incluso se invierte para el nivel bajo de educación, lo que sugiere que el enfoque dinámico del índice RSH-UF captura mejor la evolución de la rutinización dentro de las ocupaciones y, con ello, el componente específicamente composicional que conecta automatización y brecha salarial de género.

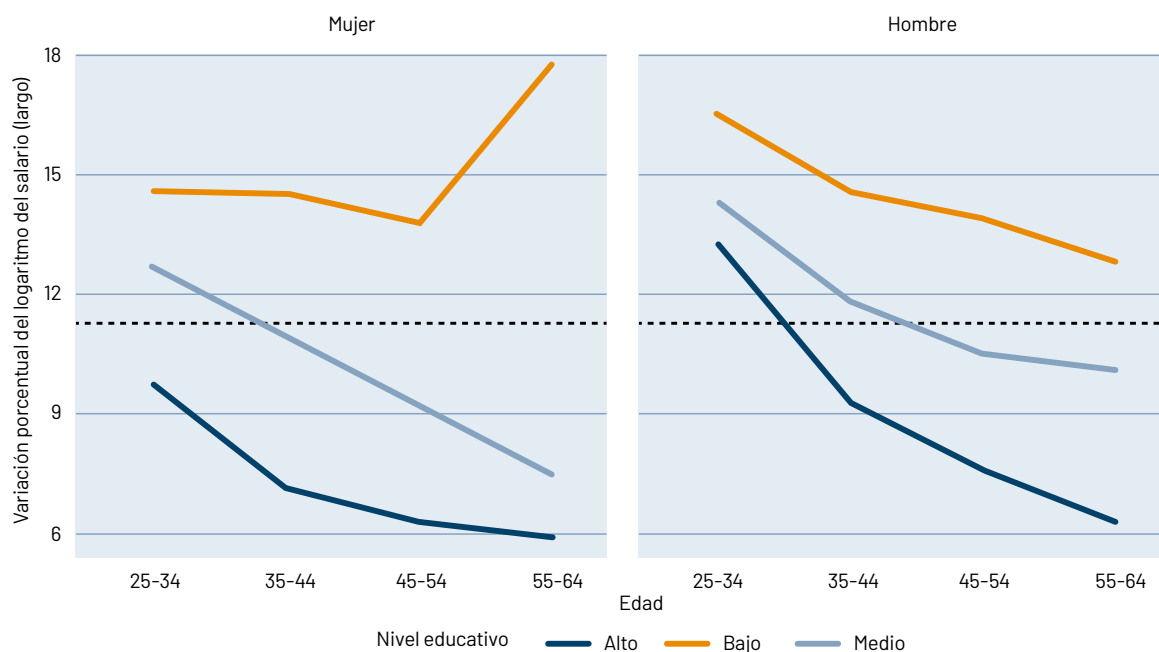
Además, el propio gráfico 4 revela dos regularidades que amplifican esta lectura. Primero, aparece un gradiente educativo claro, siendo la exposición

a la automatización mayor cuanto menor es el nivel educativo. Esto, combinado con la mayor presencia masculina en ocupaciones de baja y media cualificación, refuerza la asimetría por sexo. Segundo, se observa una pauta por edad: la exposición tiende a ser más alta entre los grupos jóvenes y menor en las cohortes de mayor edad, lo que acentúa el sesgo de exposición masculino, dado que la entrada de hombres jóvenes en ocupaciones rutinarias ha sido relativamente más intensa. Ambas regularidades encajan con la teoría de tareas y ayudan a entender por qué, al excluir la influencia de las nuevas tecnologías, la compresión de la brecha de género emerge como un efecto agregado.

Para traducir esta exposición diferencial en resultados salariales por sexo, el análisis pasa de la fotografía inicial a los efectos estimados por cohortes. El gráfico 5 compara, para el período 2000-2019, el salario observado con el salario contrafactual sin automatización para cada com-

GRÁFICO 5

EL EFECTO DE LA AUTOMATIZACIÓN POR SEXO, EDAD Y NIVELES DE EDUCACIÓN



Nota: La línea discontinua negra muestra la diferencia media entre el salario hipotético y el salario real en todos los grupos.

Fuente: Palomino et al. (2025).

binación posible de sexo, edad y educación. La interpretación es clara desde la óptica de género: valores positivos indican que ese grupo habría tenido salarios más altos sin automatización, por lo que el impacto de la automatización ha sido relativamente más adverso.

Así, emergen tres pautas clave con implicaciones de género:

1. *Gradiente educativo pronunciado.* Las mayores pérdidas salariales relativas se concentran en el nivel bajo de educación, un segmento donde los hombres son más intensivos en tareas rutinarias. En la educación media, las pérdidas se moderan, y en el nivel de educación alta, el efecto adverso tiende a neutralizarse.
2. *Diferencial por sexo.* A igualdad de edad y educación, las mujeres suelen experimentar impactos menos negativos que los hombres, especialmente en los niveles de educación media y alta, lo que es coherente con una menor exposición femenina a las tareas automatizables dentro de esas categorías.
3. *Pauta por edad y vulnerabilidad.* El efecto adverso tiende a reducirse con la edad. Sin embargo, las excepciones más visibles se localizan en las mujeres de bajo nivel educativo, donde la combinación de menor movilidad ocupacional y la alta sustitución de tareas amplifica la vulnerabilidad relativa de este grupo.

Para cerrar la explicación de este enfoque de género, la conjunción de ambas piezas —exposición inicial (gráfico 4) y efectos salariales contrafactuales (gráfico 5)— da lugar a un mecanismo claro. Una mayor exposición masculina a la automatización en ocupaciones de cualificación intermedia, unida al castigo relativo al nivel bajo de educación, explica por qué la automatización eleva la desigualdad agregada (al vaciar el centro) y, simultáneamente, estrecha la brecha salarial de género (por un potente efecto composicional). Desde el punto de vista de la política pública, este resultado sugiere ciertas prioridades con perspectiva de género: recualificación y movilidad dirigida a los hombres en ocupaciones rutinarias

de baja y media cualificación; itinerarios de transición hacia funciones menos automatizables con apoyos específicos para mujeres de baja educación, que muestran bolsas de riesgo persistente; y un seguimiento de la difusión de las tecnologías complementarias en la parte alta de la distribución para evitar que nuevas dinámicas de complementariedad reviertan los avances logrados en la brecha salarial entre hombres y mujeres.

IV. CONCLUSIONES

Este trabajo concluye que la profunda transformación reciente del mercado laboral español está estrechamente ligada al cambio tecnológico y a su sesgo por tareas. A partir de un registro del empleo por percentiles salariales, documentamos una secuencia que combina fases de polarización con un tramo final de mejoramiento en la parte alta, en línea con la sustitución de tareas rutinarias y la complementariedad de tecnologías avanzadas como la IA con tareas abstractas. Al llevar este diagnóstico al terreno distributivo, un enfoque contrafactual permite aislar la contribución de la tecnología a la desigualdad salarial: la automatización explica una parte sustantiva del aumento de la dispersión, principalmente por el vaciado del segmento medio intensivo en rutinas, mientras que la IA, en su fase inicial de adopción, tiende a concentrar ganancias en la cola alta. Estos resultados son coherentes con la teoría de tareas y robustos a distintas métricas de exposición.

En clave de género, los efectos no son homogéneos, ya que la mayor exposición masculina a ocupaciones de cualificación media intensivas en tareas rutinarias hace que la automatización, aun elevando la desigualdad total, contribuya a reducir la brecha salarial entre mujeres y hombres por un mecanismo composicional. Para la IA, los efectos sobre la brecha dependen de la medida de exposición utilizada y del patrón de complementariedad entre tareas y tecnologías, lo que sugiere que la incidencia de la IA no es uniforme entre colectivos.

Los resultados ponen de relieve heterogeneidades relevantes por sexo, edad y educación. La penalización recae con mayor intensidad en traba-

jadores de baja cualificación y en cohortes jóvenes ubicadas en ocupaciones rutinarias; en cambio, los grupos con mayor dotación de tareas abstractas capturan con más probabilidad las ganancias de productividad asociadas a las nuevas tecnologías. Esta geografía de impactos es clave para diseñar intervenciones eficaces.

El análisis causal, basado en instrumentos, se interpretó a la luz de sus supuestos. Si bien la estrategia *shift-share* y el uso de medidas de exposición basadas en tareas internacionales mitigan los problemas de endogeneidad, se aconseja cautela al extrapolar las conclusiones fuera del período y contexto estudiados.

Finalmente, las implicaciones de políticas públicas que se derivan de este análisis apuntan a la necesidad de un paquete de medidas orientado por tareas y con perspectiva de género que combine tres ejes fundamentales para gestionar la transición tecnológica:

1. *Fomentar la recualificación y movilidad ascendente* en ocupaciones rutinarias, especialmente las masculinizadas, mediante formación modular acreditable, reconocimiento de competencias transferibles y apoyos específicos al reempleo.
2. *Promover el acceso efectivo de las mujeres a habilidades y ocupaciones complementarias con IA*, lo que incluye la alfabetización en IA aplicada, el análisis de datos y la gestión de procesos digitales, junto con mecanismos que reduzcan los sesgos de selección y promoción.
3. *Reforzar la contención de la desigualdad agregada* a través de marcos de negociación colectiva, salarios mínimos bien calibrados, políticas de competencia en mercados donde puedan emerger rentas de posición y sistemas tributario-redistributivos que amortigüen los extremos.

Este enfoque dual permite aprovechar el potencial igualador del cambio tecnológico sin agravar la dispersión salarial.

BIBLIOGRAFÍA

- Acemoglu, D. (2025).** The simple macroeconomics of AI. *Economic Policy*, 39(120).
- Acemoglu, D., y Autor, D. (2011).** Skills, tasks and technologies: Implications for employment and earnings. En O. Ashenfelter y D. Card (Eds.), *Handbook of Labor Economics* (vol. 4, pp. 1043-1171). Elsevier.
- Acemoglu, D., y Johnson, S. (2024).** Learning from Ricardo and Thompson: Machinery and labor in the early Industrial Revolution—and in the age of AI. *Annual Reviews of Economics*, 16, 597-621.
- Acemoglu, D., y Restrepo, P. (2020).** Robots and jobs: Evidence from US labor markets. *Journal of Political Economy*, 128(6), 2188-2244.
- Albanesi, S., Dias da Silva, A., Jimeno, J. F., Lamo, A., y Wabitsch, A. (2025).** New technologies and jobs in Europe. *Economic Policy*, 40(121), 71-139.
- Anghel, B., De la Rica, S., y Lacuesta, A. (2014).** The impact of the Great Recession on employment polarization in Spain. *SERIEs*, 5(2-3), 143-171.
- Autor, D. H., y Dorn, D. (2013).** The Rise of the Machines: How Computers Have Changed Work. *American Economic Review*, 103(5), 1573-1602.
- Autor, D. H., Katz, L. F., y Kearney, M. S. (2006).** The Polarization of the U.S. Labor Market. *AEA Papers and Proceedings*, 96(2), 189-194.
- Autor, D., Levy, F., y Murnane, R. J. (2003).** The skill content of recent technological change: An empirical exploration. *The Quarterly Journal of Economics*, 118(4), 1279-1333.
- Biagi, F., y Sebastian, R. (2020).** Technologies and "Routinization". En K. F. Zimmermann (Ed.), *Handbook of labor, human resources and population economics*. Springer.
- Brynjolfsson, E., Mitchell, T., y Rock, D. (2018).** What can machines learn, and what does it mean for occupations and the economy? *American Economic Review Papers and Proceedings*, 108: 43-47.
- Cerina, F., Moro, A., y Rendall, M. (2021).** The role of gender in employment polarization. *International Economic Review*, 62(4), 1655-1691.

- Felten, E. W., Raj, M. y Seamans, R. (2018).** A method to link advances in artificial intelligence to occupational abilities. *AEA Papers and Proceedings*, 108, 54–57.
- Frey, C. B. (2019).** *The Technology Trap: Capital, Labor, y Power in the Age of Automation*. Princeton University Press.
- Goos, M., y Manning, A. (2007).** Lousy and lovely jobs: The rising polarization of work in Britain. *Review of Economics and Statistics*, 89(1), 118–133.
- Goos, M., Manning, A., y Salomons, A. (2014).** Explaining Job Polarization: Routine-Biased Technological Change and Offshoring. *American Economic Review*, 104(8), 2509–2526.
- Graetz, G., y Michaels, G. (2018).** Robots at Work. *Review of Economics y Statistics*, 100(5), 753–768.
- Mokyr, J., Vickers, C., y Ziebarth, N. L. (2015).** The history of technological anxiety and the future of economic growth: Is this time different? *Journal of Economic Perspectives*, 29(3), 31–50.
- Palomino, J. C., Rodríguez, J. G., Salas-Rojo, P., y Sebastian, R. (2025).** *New technologies and the rise of wage inequality* (Mimeo).
- Rodríguez, J. G., Sebastian, R., y Zheng, B. (2025).** *The effects of new technologies on occupational change* (Mimeo).
- Rodríguez, J. G., y Sebastian, R. (2022).** *Automatización, polarización laboral e igualdad socioeconómica*. Fundación Cotec.
- Rodríguez, J. G., y Sebastian, R. (2023).** Desigualdad de las rentas de mercado en España: procesos generadores y políticas. *Cuadernos Económicos de ICE*, 105, 37–61.
- Sebastian, R. (2018).** Explaining job polarization in Spain from a task perspective. *SERIEs*, 9, 215–248.
- Sebastian, R. (2022).** The labour market, income per capita and welfare in Europe: An overview of the last two decades. *Ekonomiaz*, 101, 158–183.
- Sebastian, R. (2023).** Gender Job Polarisation. X ECINEQ Meeting, Aix-en-Provence (Francia).
- Sebastian, R. (2025).** *La evolución de la estructura ocupacional en España: Un análisis de largo plazo (1975-2024)*. Informe Fundación FOESSA. En prensa.
- Spitz-Oener, A. (2006).** Technical change, job tasks, y rising educational demands: Looking outside the wage structure. *Journal of Labor Economics*, 24(2), 235–270.
- Tinbergen, J. (1974).** Substitution of graduate by other labour. *Kyklos*, 27, 217–226.
- Webb, M. (2020).** The impact of artificial intelligence on the labor market. *SSRN Electronic Journal*.
- Wright, E. O., y Dwyer, R. E. (2003).** The patterns of job expansions in the USA: A comparison of the 1960s and 1990s. *Socio-Economic Review*, 1(3), 289–325.